



Pro gradu -tutkielma
Fysikaalisten tieteiden maisterinohjelma
Meteorologia

Sääparametrien vaikutus kaukolämmön tarpeeseen

Elina Heinilä

25.4.2019

Ohjaajat:

Dos. Jouni Räisänen ja

Prof. Heikki Järvinen

Tarkastajat:

Prof. Heikki Järvinen ja

Dos. Jouni Räisänen

HELSINGIN YLIOPISTO
MATEMAATTIS-LUONNONTIETEELLINEN TIEDEKUNTA
PL 64 (Gustaf Hällströmin katu 2a)
00014 Helsingin yliopisto

Tiedekunta – Fakultet – Faculty Matemaattis-luonnontieteellinen		Koulutusohjelma – Utbildningsprogram – Degree programme Fysikaalisten tieteiden maisterinohjelma Meteorologia	
Tekijä – Författare – Author Elina Heinilä			
Työn nimi – Arbetets titel – Title Sääparametrien vaikutus kaukolämmön tarpeeseen			
Työn laji – Arbetets art – Level Pro gradu -tutkielma		Aika – Datum – Month and year 25.4.2019	Sivumäärä – Sidantal – Number of pages 59
Tiivistelmä – Referat – Abstract <p>Tämän meteorologian pro gradu -tutkielman tarkoituksena on etsiä mahdollisia yhteyksiä sääparametrien ja kaukolämmön tuotannon välillä. Tutkielma perustuu Etelä-Suomen rannikolla sijaitsevan kaupungin kaukolämmön tuotantotietoihin vuosina 2015 – 2018 ja vastaavan ajanjakson säähavaintoihin kyseisellä paikkakunnalla. Tutkielmassa yhteyksiä etsitään tilastollisia menetelmiä käyttäen korrelaatio- ja regressioanalyysien avulla.</p> <p>Tulosten perusteella ulkoilman lämpötilan vaikutus lämmöntarpeeseen on suuri, mutta sen sijaan muiden sääsuureiden vaikutus on vähäistä. Lisäksi sosiaalisten vaikutusten, kuten lämmöntarpeen vuorokausi- ja viikonpäivävaihtelun huomioiminen on tärkeää. Lämmöntarpeen ennustaminen onnistuu parhaiten regressiomallin avulla, jossa huomioidaan sekä ulkoilman lämpötila että sosiaaliset vaikutukset. Lämmöntarpeen ennustetarkkuus parani huomattavasti mallin rajoittuessa pelkästään ns. lämmityskaudelle eli loka-maaliskuun väliselle ajanjaksolle. Mallin havaittiin epäonnistuvan erityisesti tilanteissa, joissa ulkoilman lämpötila muuttuu nopeasti. Ennustetarkkuuden parantamiseksi malliin tulisikin lisätä mallin hitauteen liittyvä komponentti.</p> <p>Tutkielma on tarkoitettu niin meteorologia- kuin insinööritaustaisille lukijoille. Meteorologiataustaisille lukijoille tutkielman tarkoitus on kertoa lyhyesti kaukolämpöjärjestelmistä ja niihin liittyvästä tekniikasta. Meteorologiasta tietämättömille lukijoille puolestaan on tarkoitus luoda kuva eri sääsuureista ja niiden välisistä yhteyksistä sekä säähavaintojen teosta että säänennustamisesta. Näin lukija saa myös käsityksen säänennustamiseen liittyvistä epävarmuuksista, jotka on hyvä tiedostaa kaukolämmöntarpeen arvioinnin perustuessa suurelta osin lämpötilaennusteeseen.</p>			
Avainsanat – Nyckelord – Keywords Kaukolämpö, lämmöntuotannon optimointi, säähavainnot, säänennustaminen			
Säilytyspaikka – Förvaringsställe – Where deposited			
Muita tietoja – Övriga uppgifter – Additional information			

Sisällysluettelo

1. Johdanto.....	1
2. Kaukolämmön tuotanto Suomessa.....	3
2.1 Sähkömarkkinoiden toiminta Suomessa	3
2.2 Kaukolämmitys.....	4
2.3 Sähkön ja lämmön yhteistuotanto.....	6
2.4 Lämmitystarveluku	7
3. Sääsuureet	9
4. Aikaisempi tutkimus aiheesta.....	19
5. Säänennustaminen	21
5.1 Havaintoverkosto	21
5.2 Ennusteen alkutilan määrittäminen data-assimilaatiomenetelmällä	24
5.3 Ennustusmallien toiminta.....	25
5.4 Säänennustusmallit	27
5.4.1 ECMWF:n globaali malli.....	28
5.4.2 HIRLAM.....	30
5.4.3 HARMONIE	30
5.5 Ennusteiden toteutuvuus Suomessa	31
6. Kaukolämmön tuotannon riippuvuus sääolosuhteista	33
6.1 Korrelaatio- ja regressioanalyysi	33
6.2 Sosiaalinen vaikutus.....	34
6.3 Sääparametrien vaikutus	36
6.3.1 Koko vuosi	37
6.3.2 Lämmityskausi	38
6.3.3 Kevät ja kesä	40
7. Johtopäätelmät.....	43
Kiitokset	45
LÄHDELUETTELO	46
Liite 1: Sosiaaliset vaikutukset	51
Liite 2: Sääparametrien vaikutus	53
Liite 3: Regressiomallin tulokset	57

1. Johdanto

Kaukolämpö on Suomessa yleisin lämmitysmuoto ja sen osuus kaikesta Suomessa tuotetusta lämpöenergiasta on n. 46 % (Energiateollisuus, 2017). Suurin osa kaukolämmöstä tuotetaan sähkön ja lämmön yhteistuotannon avulla, joka mahdollistaa energiantuotannon paremmalla hyötysuhteella kuin sähkön ja lämmön erikseen tuottaminen. Kaukolämpöä pidetäänkin sen puolesta tehokkaana ja ympäristöystävällisenä lämmityskeinona. Kaukolämmön hyviin puoliin lukeutuvat myös sen tuottomahdollisuudet monipuolisesti eri polttoaineista. Suomessa käytettävistä polttoaineista n. 34 % on uusiutuvia ja 60 % kotimaisia (Energiateollisuus, 2017). Kaukolämpöä on mahdollista tuottaa myös lämpöpumppujen avulla, joten sen tuottaminen on mahdollista uusiutuvien keinoin tuotetun sähkön, kuten aurinko- ja tuulisähkön avulla (Talouselämä, 2019).

Ulkoilman lämpötila on tärkein kaukolämmön tarpeeseen vaikuttava tekijä (Fang ja Lahdelma, 2016). Seuraavaksi päiväksi ennustettu ulkoilman lämpötila vaikuttaakin suurelta osin arvioituun kaukolämmön tuotantomäärään ja yhteistuotantolaitoksissa siis myös arvioituun sähköntuotantomäärään. Aikaisempien tutkimusten perusteella myös muiden sääsuureiden, kuten tuulen nopeuden ja auringonsäteilyn voimakkuuden on havaittu vaikuttavan lämmöntarpeeseen. Tämän meteorologian pro gradu -tutkielman tarkoituksena on etsiä mahdollisia yhteyksiä sääparametrien ja kaukolämmön tuotannon ja kulutuksen välillä. Tutkielma perustuu Etelä-Suomen rannikolla sijaitsevan kaupungin kaukolämmön tuotantotietoihin vuosina 2015 – 2018 (Pöyry Finland Oy, 2019) ja vastaavan ajanjakson säähavaintoihin kyseisellä paikkakunnalla (Ilmatieteen laitos A). Lisäksi työssä on käytetty auringonsäteilyhavaintoja, jotka ovat peräisin Helsingin Kumpulasta. Työssä sääparametreihin verrataan nimenomaan kaukolämmön tuotantoa eikä kulutusta, jolloin myös kaukolämpöverkkoon liittyvät häviöt ja menoveden lämpötilan optimointi on voitu jättää huomiotta.

Tämän työn tarkoitus on ennen kaikkea nähdä löytyykö kaukolämmöntuotannon ja sääparametrien väliltä yhteyksiä tilastollisia menetelmiä käyttäen. Tutkielma on suunnattu niin meteorologia- kuin insinööri- ja teknologia-aloille lukijoille. Tavoitteeni on, että tämän tutkielman luettuaan meteorologia- ja insinööri-aloille lukijoille, joilla ei ole aikaisempaa taustaa meteorologiasta tämän tutkielman tarkoituksena on antaa johdatus eri sääsuureista ja niiden välisistä yhteyksistä sekä

säähavainnoista että säänennustuksesta. Tämän vuoksi meteorologiasta kertovat teoriaosuudet ovat käsittelyltään melko yksinkertaisia.


Tutkielman 2. luku on suunnattu meteorologiataustaisille lukijoille ja siinä käydään lyhyesti läpi sähkömarkkinoiden toimintaa Suomessa sekä kaukolämpöjärjestelmiä että -tekniikkaa. Luvussa 3 käydään tarkasti läpi eri sääsuureita ja niiden välisiä yhteyksiä. Neljännessä luvussa käsitellään kaukolämmön ja sääsuureiden välille aikaisemmin tehtyjen tutkimusten tuloksia. Luvussa 5 käydään läpi säänennustamisen peruseriaatteita. Luvun alussa kerrotaan säähavaintojen teosta, jonka jälkeen käsitellään ennusteajojen alkutilan määrittystä ja itse ennustusmallien toimintaa. Lisäksi luvussa 5 kerrotaan eri säänennustusmalleista ja niiden luokittelutavoista, Suomessa yleisesti käytetyistä säämalleista ja säänennusteiden toteutuvuudesta Suomessa. Luku 6 perustuu kokeelliseen aineistoon ja siinä käsitellään kaukolämmön tuotantotehon riippuvuutta eri sääolosuhteista. Tutkielman tuloksia esitellään luvun 6 lisäksi myös liitteissä 1-3.

2. Kaukolämmön tuotanto Suomessa

Tämän kappaleen tarkoitus on johdattaa meteorologiataustaisia henkilöitä lyhyesti kaukolämpöjärjestelmiin ja -tekniikkaan. Tämän tutkielman tarkoitus on löytää kaukolämmön tuotannon ja sääsuureiden välisiä korrelaatioita, joiden avulla saadaan tietoa sekä lämmön tuotannon että kulutuksen ja sääsuureiden välisistä yhteyksistä. Lämmön tuotannon optimointi on tärkeää ennen kaikkea sähköä ja lämpöä yhteistuotannolla tuottaville voimalaitoksille, sillä tuotettu sähkömäärä on verrannollinen tuotettuun lämpömäärän. Koska nimenomaan virheellisesti ennustettu sähköntuotantomäärä aiheuttaa voimalaitoksille lisäkustannuksia, tässä kappaleessa käsitellään sekä sähkömarkkinoiden toimintaa ja sähkönhinnan määräytymistä Suomessa että sähkön ja lämmön yhteistuotantoa. Kappaleen lopussa käsitellään myös lämmöntarvelukua, joka on energiatekniikassa käytetty perinteinen mutta yksinkertainen tapa arvioida tietyn paikkakunnan vuosittaista lämmön kulutusta.

2.1 Sähkömarkkinoiden toiminta Suomessa

Suomi kuuluu muiden Pohjoismaiden ja Baltian maiden ohella Nord Pooliin eli pohjoismaiseen sähköpörssiin. Nykyisin Nord Poolin markkina-alue kattaa myös Keski-Euroopan maita, kuten Ison-Britannian ja Saksan (Nord Pool). Suomessa sähkönhinta määräytyy pääosin Nord Poolin Spot-markkinoilla sähkön kysynnän ja tarjonnan mukaisesti. Spot-markkinoilla tuntikohtainen sähkön hinta (€/MWh) muodostuu myyntiä edeltävänä päivänä kello 12 UTC (kuva 2-1) sähkön osto- ja myyntitarjousten leikkauspisteeseen.



Kuva 2-1. Sähkönhinnan määräytyminen sähkön kysynnän ja -tarjonnan leikkauspisteeseen (Wind Energy The Facts).

Tuntikohtainen sähkönhinta määräytyy siis jo 12 – 36 tuntia ennen sähköntoimitusta. Tähän mennessä jokaisen Nord Pooliin sähköä myyvän tuottajan on tiedettävä, kuinka paljon sähköä on tuntikohtaisesti myymässä ja mihin hintaan. Sähkömarkkinalaki velvoittaa jokaisen sähkömarkkinoilla toimivan osapuolen huolehtimaan, että spot-markkinoilla sovittu tuntikohtainen sähköntuotanto ja -kulutus toteutuvat. Virheellisesti ennustettu sähköntuotantomäärä voi koitua voimalaitokselle kalliiksi. Pienen kokoluokan voimalaitokselle ennustetun ja toteutuneen sähköntuotannon välinen virhe aiheuttaa karkeasti n. 0.5 – 1 € häviön jokaista tuotettua MWh:a kohden (Pöyry Finland Oy, 2019).

Mikäli sähkön osto- ja myyntitarpeissa tapahtuu muutoksia Spot-markkinoiden sulkeutumisen jälkeen, on kaupankäynti vielä mahdollista Elbas-markkinoilla (Ollikka, 2017). Suomessa Elbas-markkinat toimivat Suomen ja Ruotsin välillä. Elbas-markkinat sulkeutuvat kaksi tuntia ennen sähkön fyysistä toimitusta. Tämän jälkeen sähkökauppa on mahdollista vielä säätösähkö- ja reservimarkkinoiden kautta, joilla sähkön hinta määräytyy kunkin käyttötunnin ylös- tai alassäätöhinnan mukaisesti (Ollikka, 2017; Fingrid).

2.2 Kaukolämmitys

Kaukolämmön tarkoituksena on tuottaa energiaa niin rakennusten kuin käyttöveden lämmittämiseen (Energiateollisuus, 2006). Kaukolämpö tuotetaan pääosin keskitetyissä voimalaitoksissa tai lämpökeskuksissa, joista se jaetaan eteenpäin asiakkaille kaukolämpöverkon välityksellä. Kaukolämpöä käytetään sekä asuinrakennusten, teollisuus- ja liikerakennuksien että julkistenkin rakennusten ja käyttöveden lämmittämiseen. Vaikka kaukolämmön markkinaosuus on laskenut sitten vuoden 2006, vuonna 2016 sen markkinaosuus ylsi yhä 46 prosenttiyksikköön taaten lämpöä n. 2,8 miljoonan suomalaisen kotitalouksiin (Energiateollisuus, 2017). Samana vuonna kaukolämpöä myytiin Suomessa 33,7 TWh, joka vastaa noin yhtä kymmenesosaa kyseisen vuoden 371 TWh:n energian kokonaiskulutuksesta Suomessa (Tilastokeskus, 2017). Suomi on maailmanlaajuisesti yksi kaukolämpötekniikan johtavista maista. Suomen lisäksi kaukolämpö on yleinen lämmitysmuoto mm. Pohjois-Amerikassa, muissa Pohjoismaissa, Itä- ja Keski-Euroopassa, Venäjällä ja Kiinassa (Cai ym., 2015; Energiateollisuus, 2006).

Kaukolämpöjärjestelmän toiminta perustuu energian siirtoon kaukolämpöverkostossa kiertävän väliaineen mukana. Väliaineena voi toimia joko vesi tai höyry, joista vesi on huomattavasti yleisempi vaihtoehto (Energiateollisuus 2006). Keskitetty lämmöntuotanto


tapahtuu joko pelkkää lämpöä tuottavassa lämpökeskuksessa tai sekä lämpöä että sähköä tuottavassa voimalaitoksessa, josta käytetään myös nimitystä yhteistuotanto (CHP, 'Combined Heat and Power'). Itse kaukolämpöverkosto muodostuu meno- ja paluuputkista koostuvista kaukolämpöjohdoista (Fang ym., 2016). Lämmitetty vesi siirtyy asiakkaalle menovesiputkea pitkin, jossa paineistetun menoveden lämpötila vaihtelee tavallisesti n. 75 – 115 °C välillä. Suomessa kaukolämpöasiakkaat ovat liittyneet kaukolämpöverkkoon ns. epäsuoran kytkennän kautta. Tämä tarkoittaa sitä, että asiakkaalla on oma lämmityskiertojärjestelmä, johon lämpöenergia välitetään lämmönsiirtimen kautta. Menovesiputkessa saapunut vesi sen sijaan ei siirry asiakkaan käyttöön, vaan viilennyt vesi siirtyy paluuputkea pitkin takaisin tuotantolaitokseen, yleensä alkuperäistä n. 30 – 60 °C viileämpänä (Laaksonen, 2018; Energiateollisuus, 2006). Kaukolämpöverkostossa siirtyneen energian määrän suuruuteen vaikuttaa meno- ja paluuvesien lämpötilojen lisäksi myös mm. väliaineen virtausnopeus (Fang ja Lahdelma, 2016).

Kaukolämmön hyvinä puolina pidetään erityisesti sen korkeaa energiatehokkuutta ja mahdollisuutta käyttää laajalti erilaisia polttoaineita (Energiateollisuus, 2017). Tämä mahdollistaa niin uusiutuvien kuin kotimaisten polttoaineiden käytön. Lisäksi kaukolämpö on käyttäjän kannalta erittäin helppokäyttöinen ja luotettava lämmitysratkaisu. Kaukolämpöjärjestelmän energiatehokkuutta voidaan parantaa entuudestaan liittämällä sen toimintaan lämpövarasto, kuten esimerkiksi lämpöakku. Tarpeeksi tiheään asutulla alueella kaukolämpö on lisäksi edullinen lämmityskeino. Sen sijaan harvaan asutuilla alueilla kaukolämpö ei ole kovinkaan kannattava ratkaisu kalliin alkuinvestointikustannuksen vuoksi. Järjestelmän huonoihin puoliin lukeutuvat lämpöhäviöt lämmön jakelun aikana, joten pitkiä matkoja lämpöä siirrettäessä häviöt kasvavat yhä suuremmiksi.

Biomassasta yhteistuotantolaitoksella tuotettu kaukolämpö valikoitui parhaaksi lämmöntuotantotavaksi Konnun ym. (2015) tutkimuksessa, jossa arvioitiin parasta lämmityskeinoa uudisasuinaluekohteeseen Etelä-Suomen rannikolla. Tutkimuksessa arvioitiin lämmöntuotantomenetelmien ympäristö- ja käyttäjäystävällisyyttä sekä teknistä että taloudellista puolta. Päätös perustui niin kaukolämmön helppokäyttöisyyteen, ympäristövaikutuksiin kuin investointikustannuksiin. Toiseksi vertailussa sijoittuneet lämpöpumput saivat sen sijaan kannatusta sosiaalisen hyväksyttävyyden ja käyttökustannusten vuoksi.

2.3 Sähkön ja lämmön yhteistuotanto


Suomessa n. kolme neljäsosaa kaukolämmön tuotannosta tapahtuu lämmön ja sähkön yhteistuotantona. Yhdistetty sähkön- ja lämmöntuotanto on erillistuotantoja huomattavasti tehokkaampi tuotantotapa hyötysuhteen ollessa jopa 90 % (Pori Energia). Näin ollen se on myös erinomainen tapa vähentää polttoaineen kulutusta. Erikseen tuotettuna sähköntuotannon hyötysuhde vaihtelee n. 40 – 50 % välillä ja lämmöntuotannon n. 80 – 90 % välillä. Sähköntuotanto vaatii huomattavasti korkeampaa lämpötilaa kuin lämmöntuotanto, johon riittää myös matalampi lämpötila. Yhteistuotannon erinomainen hyötysuhde perustuu siihen, että käyttämällä osa sähköntuotantoon vaadittavasta korkeasta lämpötilasta lämmöntuotantoon voidaan tuottaa moninkertainen määrä lämpöenergiaa verrattuna mahdolliseen sähköntuotantomäärään. Yhteistuotantolaitosten rakennusaste tarkoittaa tuotetun sähkömäärän suhdetta tuotettuun lämmönmäärään (Energiateollisuus, 2006).



Kuva 2-2. Kaukolämmön tuotantoon käytettyjen polttoaineiden osuudet Suomessa vuonna 2016 (Energiateollisuus 2017).

Vuonna 2016 Suomessa tuotetusta kaukolämmöstä 92 % tuotettiin perinteisesti polttoaineilla ja loput 8 % talteenoton ja lämpöpumppujen avulla (Energiateollisuus, 2017). Kivihiilen osuus energialähteenä oli yhä 24 %, mutta metsäpolttoaineiden, teollisuuden puutähteen ja muun biomassan yhteenlaskettu osuus oli 34 % (kuva 2-2). Lisäksi energialähteistä 60 % oli kotimaisia. Kaukolämmön tuotantoon käytettyjen polttoaineiden osuudet ovat muuttuneet paljon vuodesta 1976 lähtien (Kuva 2-3). Öljyn osuus on vähentynyt todella voimakkaasti. Kivihiilen käytön osuus oli suurimmillaan 1980-luvun aikana, jonka jälkeen sen osuus on pysynyt melko

tasaisena. Sen sijaan maakaasun ja erityisesti biopolttoaineiden osuudet ovat kasvaneet selvästi kaukolämmön energialähteinä. Maakaasun ja biopolttoaineiden osuudet tulevat kasvamaan yhä reilummin, sillä Suomen on tarkoitus luopua kokonaan kivihiilen käytöstä vuoteen 2030 mennessä (Eduskunta, 2018).



Kuva 2-3. Kaukolämmön tuotantoon käytettyjen polttoaineiden prosentuaaliset osuudet Suomessa vuosina 1976–2016 (Energiateollisuus 2017).

2.4 Lämmitystarveluku

Lämmitystarveluku eli astepäiväluku on perinteinen, mutta erittäin karkea mittari tietyn paikkakunnan lämmöntarpeen arvioimiseen. Sitä käytetään rakennusten energian kulutuksen seurantaan ja lämmitysenergiatarpeen kuvaamiseen. Lämmitystarveluvun avulla voidaan verrata joko eri paikkakunnilla sijaitsevien rakennusten lämmönkulutusta tai saman rakennuksen eri kuukausien ja vuosien välisen lämmönkulutuksen vaihtelua (Motiva, 2017). Lämmitystarveluku onkin kehitetty rakennusten lämmityskulutuksen seuraamista varten eri paikkakunnilla ja sen perusteella lämmitysmäärä on yksinkertaisesti verrannollinen sisä- ja ulkolämpötilan erotukseen.

Yleisimmin käytetään lämmitystarvelukua S17, joka lasketaan yhdelle vuorokaudelle sisälämpötilana oletetun + 17 °C ja ulkolämpötilan vuorokauden keskilämpötilan erotuksena. Lukua laskettaessa oletetaan, että lämmityksen tarve on ainoastaan kun vuorokauden keskilämpötila on alle 10 °C tammi-kesäkuu välisenä ajanjaksona ja alle 12 °C heinä-joulukuussa (Motiva, 2017). Näin ollen lämmitystarveluku ei sisällä päiviä, joiden keskilämpötila keväällä on yli + 10 °C ja syksyllä yli + 12 °C. Pidemmän ajanjakson lämmöntarveluku saadaan laskemalla halutun ajan vuorokausien lämmöntarveluvut yhteen (Energiateollisuus, 2006). Kuukauden lämmitystarveluku saadaan siis summaamalla

vuorokausien lämmitystarveluvut ja koko vuoden lämmitystarveluku puolestaan kuukausien lämmitystarvelukujen summana kaavan (2.1) mukaisesti:

$$S = \sum_{u=1}^n (17 - T_u) \cdot \Delta t \quad (2.1)$$

Yhtälössä (2.1) S kuvaa lämmitystarpeenlukua, T_u vuorokauden keskilämpötilaa, Δt aika-askeleen pituutta (vuorokausi tai kuukausi) ja n päivien tai kuukausien kokonaismäärää. Lämmitystarveluku on siis sitä suurempi, mitä kylmempi ulkoilman lämpötila on.

3. Sääsuureet


Lämmöntuotannon optimointi sääsuureita ja -ennusteita hyväksi käyttäen vaatii käyttäjältään ymmärrystä niin ilmakehän ja havaintosuureiden ominaisuuksista kuin itse havaintojärjestelmistä ja säänennustamisesta. Kirjallisuudessa on tutkittu aiemminkin eri sääsuureiden vaikutusta lämmöntarpeeseen. Kirjallisuuslähteestä riippuen ulkoilmanlämpötilan lisäksi auringonsäteilyn, tuulen nopeuden ja ilmankosteuden on havaittu vaikuttavan lämmöntarpeeseen. Tämän kappaleen tarkoituksena on luoda lyhyt kuva ilmakehän sääsuureista ja niiden välisistä yhteyksistä ei-meteorologiaustaisille lukijoille. Lämpötila, paine, kosteus ja tuuli ovat ilmakehän perushavaintosuureita: niiden avulla voidaan laskea muita säämuuttujia, joita ei pystytä havainnoimaan suoraan ilmakehästä (Alatalo, 2009). Ilman kosteutta tarkastellaan varsin perusteellisesti, sillä se on ilmakehän toiminnan kannalta merkittävä tekijä. Vaikka ilmakehän kokonaismassasta vain n. 0.3 % on vesihöyryä, liittyy suurin osa sääilmiöistä veden ja sen olomuodon muutoksiin, jotka sitovat samalla suuria energiamääriä (Ruostenoja, 1996). Lisäksi ilmankosteuden ja lämpötilan välillä on voimakas riippuvuus.

Lämmöntarpeen optimoinnin kannalta on mielenkiintoista tutkia, miten muut sääsuureet vaikuttavat yhdessä ilman lämpötilan kanssa. Tämän vuoksi tässä luvussa käsitellään 'tuntuu kuin' -lämpötilaa, jossa huomioidaan tuuli, säteilyn ja ilman kosteuden vaikutukset lämpötilan tuntuun. "Tuntuu kuin" -lämpötilan ja lämmön kulutuksen väliseen yhteyteen perehdytään myöhemmin kappaleessa 6. "Tuntuu kuin" -lämpötilaa ja sääsuureita käsitellessä esitetään myös niiden kuukausittaiset keskiarvot vuosina 2015 – 2018 tässä työssä muutenkin käytettyjen havaintotietojen pohjalta (Ilmatieteen laitos A).

Lämpötila T [°C, K]

Lämpötilaa mitataan sekä Celsius- että Kelvin-asteikoilla. Kelvin-asteikosta käytetään myös nimitystä absoluuttinen asteikko. Lämpötila syntyy ilmamolekyylien lämpöliikkeestä ja on luonnollisesti sitä korkeampi, mitä suurempi liike-energia ilmamolekyyleillä on. Absoluuttisen lämpötila-asteikon nollakohta (0 K) määräytyy sen lämpötilan mukaan, jossa kaikki lämpöliike on pysähtynyt. Celsius-asteikon nollakohta puolestaan määräytyy veden sulamispisteen 0 °C eli 273,15 K mukaan. Celsius- ja Kelvin asteikkojen jakoväli on sama toisin kuin esimerkiksi Fahrenheit-asteikolla, jota myös käytetään lämpötilan mittaamiseen (Ruostenoja, 1996).

Lämpötilahavainnot tehdään yleensä kahden metrin korkeudelta lämpötila-anturin avulla. Anturin tulee sijaita hyvin tuulettuvan säteilysuojan sisällä, jotta mittaustulos ei vääristy auringonsäteilyn vuoksi (Rinne ja Haapanala, 2009). Näin anturi pysyy myös suojassa sateelta. Lämpötilan kuukausittaisten keskiarvojen vaihtelu havaintopaikkakunnalla vuosina 2015 – 2018 on esitetty kuvassa 3-1. Tarkastellulla ajanjaksolla kuukausilämpötilat vaihtelivat -8,7 °C ja 20,5 °C välillä.



Kuva 3-1. Lämpötilan kuukausikeskiarvot vuosina 2015 – 2018 Etelä-Suomen rannikolla sijaitsevalla paikkakunnalla 2 m korkeudella (Ilmatieteen laitos A).

Paine p [Pa, hPa, mb]


Fysiikassa paine tarkoittaa nesteen tai kaasun molekyylien lämpöliikkeestä pinta-alayksikköä kohden kohdistuvaa voimaa ja sen yksikkö on $\left[\frac{N}{m^2}\right]$ eli [Pa]. Meteorologiassa paineelle käytetään yleisemmin yksiköitä millibaari [mb] tai hehtopascal [hPa]. Yksi millibaari vastaa suuruudeltaan yhtä hehtopascalia.

Ilmanpaine tarkoittaa käytännössä pinta-alayksikköön kohdistuvaa yläpuolella olevan ilmapatsaan painoa ja luonnollisesti se laskee nopeasti ilmakehässä ylöspäin mentäessä (Ruosteenoja, 1996). Koska ilmanpaine vaihtelee korkeuden funktiona, mittatulos redusoidaan eli muutetaan laskennallisesti merenpinnan tasolle. Keskimääräinen ilmanpaine merenpinnalla on 1013,25 hPa. Suomessa merenpinnan tasolle redusoitu ilmanpaine on vaihdellut karkeasti 940 hPa ja 1065 hPa välillä. Ilmanpaineen kuukausikeskiarvot vaihtelivat 1002 hPa ja 1028 hPa välillä vuosina 2015 – 2018 havaintopaikkakunnalla (kuva 3-2). Ilmanpaine mitataan paineanturin avulla.

Paineen ja lämpötilan välinen yhteys määräytyy ilmakehässä melko tarkasti ihannekaasun tilanyhtälön (3.1) perusteella:

$$p = \rho RT \quad (3.1)$$

Yhtälössä (3.1) p on ilmanpaine [Pa], ρ on ilman tiheys [$\frac{kg}{m^3}$], R on kaasun molekyylimassasta riippuva vakio (kuivalle ilmalle $R_d = 287 \frac{J}{kgK}$) ja T ilman lämpötila [K] (Puhakka, 1996).




Kuva 3-2. Merenpinnan tasolle redusoidun ilmanpaineen (hPa) kuukausikeskiarvot vuosina 2015 – 2018 Etelä-Suomen rannikolla sijaitsevalla paikkakunnalla (Ilmatieteen laitos A).

Tuuli [m/s, km/h, mpk/h]

Tuuli on ilmakehän maanpinnan suuntaisen ilmavirtauksen liikenopeutta kuvaava vektorisuure eli sillä on sekä suunta että nopeus. SI-järjestelmässä tuulen nopeuden yksikkö on [m/s]. Tuuli saa alkunsa ilmakehässä vallitsevista paine-eroista, jotka puolestaan perimmiltään johtuvat auringon lämpöenergian epätasaisesta jakautumisesta (Ruosteenoja, 1996). Matalat leveysasteet saavat huomattavasti korkeita leveysasteita enemmän auringon säteilyenergiaa ja lämpötasapainon säilymiseksi energiaa siirtyy merivirtojen ja tuulen välityksellä kohti korkeampia leveysasteita. Talvella päiväntasaajan ja korkeiden leveysasteiden välinen lämpötilaero on suurempi, jonka vuoksi talvella tuulennopeudet ovat kesäisiä korkeampia.


Ilmakehän yleisessä kiertoliikkeessä tuulisuus voidaan jakaa kolmeen tuulivyöhykkeeseen: matalien leveysasteiden pasaatituuliin, keskileveysasteiden länsituuliin ja napa-alueiden itäisiin tuuliin (Holopainen ym., 2008). Paikallisesti tuulisuuteen vaikuttavat mm. maan ja meren jakauma sekä paikalliset lämpötilat että maastonmuodot ja pinnan laatu. Lisäksi

matalapainetoiminta ja erityisesti matalapaineen keskuksen liikerata vaikuttavat huomattavasti tuulisuuteen.



Kuva 3-3. Tuuliruusu: tuulen suunta asteina ilmoitetaan siitä suunnasta, josta tuulee. Suunta 0/360 tarkoittaa, että tuuli saapuu pohjoisesta (Tuuliatlas A).

Tuulen nopeutta mitataan 10 m korkeudelta tasaiselta maanpinnalta tai merkittävien esteiden, kuten puiden latvuston, yläpuolelta. Tuulen nopeuden mittaamiseen käytetään mm. kuppi- tai akustista anemometriä, joista jälkimmäisellä voidaan mitata myös tuulen suuntaa. Tuulen suuntaa voidaan mitata myös tuuliviirin avulla. Suunta ilmoitetaan aina asteina siitä suunnasta, josta tuulee (Kuva 3-3). Suomessa yleisin tuulen suunta on lounaasta. Tuulen nopeuden kuukausittaiset keskiarvot vaihtelivat 2,4 m/s – 4,1 m/s välillä (Kuva 3-4). Kuten kuvasta 3-4 nähdään, tuulennopeuksien kuukausikeskiarvot ovat loppusyksystä ja talvella korkeampia kuin keväällä ja kesällä. Myös havaintopaikkakunnalla yleisin tuulen suunta on lounaasta (Ilmatieteen laitos A).




Kuva 3-4. Lämpötilan (°C) ja tuulen nopeuden (m/s) kuukausikeskiarvot vuosina 2015 – 2018 Etelä-Suomen rannikolla sijaitsevalla paikkakunnalla (Ilmatieteen laitos A).

Auringon säteily [W/m^2]

Ilmakehän ulkorajalle saapuva säteilyteho eli aurinkovakio on suuruudeltaan keskimäärin $1365 W/m^2$. Tästä maapallon pinnan suuntaiselle tasolle saapuu keskimäärin neljäsosa eli $341 W/m^2$ (Räisänen, 2010). Ilmakehän ulkorajalle saapuvasta säteilystä n. 20 % imeytyy ilmakehään ja 25 % heijastuu pilvistä ja ilmakehän molekyyleistä takaisen avaruuteen. Lisäksi osa säteilystä heijastuu takaisin avaruuteen maanpinnalta. Kaiken kaikkiaan takaisin avaruuteen heijastuneen säteilyn osuus on n. 30 % saapuneesta säteilystä.

Suoraan auringon suunnasta tulevasta säteilystä käytetään nimitystä suora säteily. Muulta kuin auringon suunnasta, esimerkiksi pilvistä sironneesta säteilystä käytetään nimitystä hajasäteily. Hajasäteilyn määrä on sitä suurempi, mitä matalammalta aurinko paistaa eli mitä matalampi auringon korkeuskulma on. Lisäksi hajasäteilyn osuuteen vaikuttaa luonnollisesti pilvisyyden määrä. Pilvisellä säällä korkeilla leveysasteilla auringon säteily saapuu pääosin hajasäteilynä. Globaalisäteily on suoran säteilyn ja hajasäteilyn summa eli se koostuu vaakasuoralle pinnalle koko taivaankannelta saapuvasta säteilystä (Räisänen, 2010). Muita mitattavia säteilysuureita ovat mm. maanpinnan vastasäteily, UV-säteily ja auringonpaisteen kesto aika, joista jälkimmäistä lasketaan ajalta, jolloin suoran säteilyn intensiteetti on vähintään $120 W/m^2$.

Kuvassa 3-5 on esitetty suoran säteilyn ja globaalin säteilyn kuukausikeskiarvot vuosina 2015 – 2018. Suora säteily on mitattu aurinkoa vasten kohtisuorassa suunnassa, mutta globaali säteily vaakapinta-alaa kohti. Tämän vuoksi suoran säteilyn määrä kuvassa 3-5 on suhteessa kokonaissäteilyyn liian suuri. Globaalin ja suoran säteilyn välinen erotus kertoo hajasäteilyn määrästä, jonka osuus Suomessa on huomattavasti suurempi kuin mitä kuva 3-5 antaa ymmärtää. Säteilydata on peräisin Helsingin Kumpulasta, joka maantieteellisiltä olosuhteilta vastaa hyvin havaintopaikkakuntaa. Kuten huomataan, talvisin säteilymäärä on todella alhainen. Yleensä kevät ovat Etelä-Suomen rannikolla vuoden pilvettömintä aikaa, jolloin myös hajasäteilyn osuus globaalista säteilystä on pieni. Esimerkiksi 2015 vaikuttaakin säteilyhavaintojen perusteella keskimääräistä pilvisemmältä, sillä hajasäteilyn määrä suhteessa suoraan säteilyyn on ollut melko suuri.



Kuva 3-5. Suoran säteilyn ja globaalin säteilyn (W/m²) kuukausittaiset keskiarvot Helsingin Kumpulassa vuosina 2015 – 2018 (Ilmatieteen laitos A). Suora säteily on mitattu kohtisuorassa aurinkoa vasten ja kokonaissäteily vaakapinta-alaa kohden.

Ilman kosteus ja vesihöyry ilmakehässä

Ilman kosteus tarkoittaa ilman kaasumaisessa olomuodossa sisältämää vesihöyrynpitoisuutta eli se ei sisällä esimerkiksi pilvi- ja sumupisaroita tai jääkiteitä (Puhakka, 1996). Ilman kosteudelle on olemassa useita mittoja, joista yleisimpiä esitellään seuraavaksi.

Vesihöyryn osapaine e [Pa, hPa] eli ilmassa vallitseva vesihöyryn osapaine lasketaan ihannekaasuun tilanyhtälön (3.2) mukaisesti:

$$e = \rho_v R_v T \quad (3.2)$$

Yhtälössä (3.2) ρ_v on vesihöyryn tiheys eli absoluuttinen kosteus [kg/m³], R_v on vesihöyryn kaasuvakio $R_d = 461 \frac{J}{kgK}$ (Puhakka, 1996) ja T ilman lämpötila [K]. Kokonaisilmanpaine p saadaan vesihöyryn osapaineen e ja kuivan ilman paineen $[p - e]$ summana. Vesihöyryn osapaine vaihtelee ilmakehässä normaalisti 0 – 50 hPa välillä, joten sen osuus kokonaisilmanpaineesta on huomattavasti kuivan ilman painetta pienempi.

Ilman sisältämää vesihöyrymäärää kuvataan myös ominaiskosteudella q [kg/kg, g/kg]. Ominaiskosteus (3.3) lasketaan tietyn kuvitteellisen ilmapaketin sisältämän vesihöyryn massan M_v suhteena saman paketin kokonaismassaan $M_d + M_v$:

$$q = \frac{M_v}{M_v + M_d} = \frac{\rho_v}{\rho_m} = \frac{e/R_v T}{p/R_m T} = \frac{R_m e}{R_v p} \approx 0,622 \frac{e}{p} \quad (3.3)$$

missä ρ_m on kostean ilman tiheys ja R_m kostean ilman kaasuvakio (Puhakka, 1996).

Yleisimmin ilman sisältämä vesihöyrynpitoisuus ilmoitetaan suhteellisen kosteuden R [%] avulla, joka lasketaan seuraavan yhtälön (3.4) mukaisesti:


$$R = 100 \frac{e(p-e_s)}{e_s(p-e)} \approx 100 \frac{q_v}{q_{vs}} = 100 \frac{e}{e_s} = 100 * S \quad (3.4)$$

Yhtälössä (3.4) s-alaindeksi viittaa vesihöyryn kyllästämään tilaan eli q_{vs} kuvaa kyllästysominaiskosteutta ja e_s vesihöyryn kyllästyspainetta. S on kyllästyssuhde, joka vesihöyryn suhteen ylikyllästyneelle ilmalle on > 1 , kyllästymättömälle < 1 ja juuri ja juuri vesihöyryn kyllästämälle ilmalle se on 1 (Puhakka, 1996).

Ilma voi lämpötilasta riippuen sisältää vain tietyn määrän vesihöyryä ennen kuin se saavuttaa kyllästystilan ($S = 1$), jonka jälkeen vesihöyry alkaa tiivistyä. Vesihöyryn kyllästyspaine e_s riippuu siis voimakkaasti lämpötilasta ja se voidaan laskea integroimalla Clausius-Clapeyronin yhtälö (3.5):


$$\frac{1}{e_s} \frac{de_s}{dT} = \frac{L^*}{R_v T^2} \quad (3.5)$$

Yhtälössä (3.5) L^* on olomuodon muutoslämpö eli se on joko vesihöyryn tiivistymis- tai höyrystymislämpö. Kyllästetyn vesihöyryn paine e_s on esitetty kuvassa 3-6 (vasen kuva) lämpötilan funktiona.



Kuva 3-6. Kyllästetyn vesihöyryn paine e_s (kPa) lämpötilan ($^{\circ}\text{C}$) funktiona (vasen) ja suhteellisen kosteuden (%) ja lämpötilan ($^{\circ}\text{C}$) muutos vuorokauden aikana kyllästetyn vesihöyryn osapaineen pysyessä vakiona. Oikea kuva ei vastaa Suomelle tyypillistä ilmastoa (FAO).

Kyllästyskosteus kasvaa noin 7 % lämpötilan noustessa 1 °C verran. Lämpimässä ilmassa on absoluuttisesti grammamäärältään enemmän vesihöyryä kuin kylmässä ilmassa, vaikka kylmän ilman suhteellinen kosteus olisikin korkeampi. Tämä on havaittavissa myös vuorokauden aikaisena syklinä (Kuva 3-6, oikea) ja myös vuodenaikojen välisessä suhteellisen kosteuden vaihtelussa ilmakehässä. Esimerkiksi talvisin Suomessa suhteellinen kosteus on yleensä korkea (Kuva 3-7), vaikka ilman sisältämä absoluuttinen kosteussisältö on matala. Kesäisin puolestaan lämmin ilma sisältää absoluuttisesti enemmän vesihöyryä, mutta suhteellinen kosteus voi olla matala.



Kuva 3-7. Kastepistelämpötilan (°C), lämpötilan (°C) ja suhteellisen kosteuden (%) kuukausikeskiarvot vuosina 2015 – 2018 Etelä-Suomen rannikolla sijaitsevalla paikkakunnalla (Ilmatieteen laitos A).

”Tuntuu kuin” -lämpötila [°C]

Sääennusteissa muiden sääsuureiden vaikutusta lämpötilan tuntemukseen kuvataan ”tuntuu kuin” -lämpötilan (°C) avulla (Ilmatieteen laitos B). Talvisin arkikielessä puhutaan pakkasen purevuudesta, johon ulkolämpötilan lisäksi vaikuttavat tuulisuus ja ilmankosteus. Kuumalla kesäsäällä taas puhutaan helteen tukaluudesta, johon edellä mainittujen lisäksi vaikuttaa säteilyn määrä.

”Tuntuu kuin” -lämpötilalle ei ole olemassa vain yhtä määritelmää vaan yleensä tiettyihin ilmasto-olosuhteisiin on havaittu sopivaksi jokin tietty yhtälö. Ilmatieteen laitokselta saadussa, Suomen ilmastossa toimivaksi havaitussa ”tuntuu kuin” -lämpötilan ” T_{feels} ” yhtälössä ulkoilman lämpötilaan T (°C) lisätään pakkasen purevuuden ” dT_{chill} ”, helteen tukaluuden ” dT_{heat} ” ja auringon säteilyn ” dT_{sun} ” vaikutukset alla olevan yhtälön (3.6) mukaisesti:


$$T_{feels} = T + dT_{chill} + dT_{heat} + dT_{sun} = T + (T_{chill} - T) + (T_{heat} - T) + dT_{sun} \quad (3.6)$$

$$T_{chill} = 15 + \left(1 - \frac{15}{37}\right) * T + \frac{15}{37} * (W + 1)^{0,16} * (T - 37) \quad (3.7)$$

$$T_{heat} = \frac{1,8 * T - 0,55 * (1 - RH) * (1,8 * T - 26) - 0,55 * (1 - RH_{ref}) * 26}{1,8 * (1 - 0,55 * (1 - RH_{ref}))} \quad (3.8)$$

$$T_{sun} = \frac{0,7 * C_{absorption} * RAD}{W + 10} - 0,25 \quad (3.9)$$

Pakkasen purevuuteen (yhtälö 3.7) vaikuttavat ilman lämpötila T ja tuuli W. Helteen tukaluuteen (yhtälö 3.8) puolestaan vaikuttavat ilman lämpötila T ja suhteellinen kosteus RH. Yhtälössä (3.8) $RH_{ref} = 0,5$. Auringon säteilyn vaikutus (3.9) riippuu auringon lyhytaaltosäteilyn RAD lisäksi myös tuulisuudesta W. Yhtälössä (3.9) $C_{absorption} = 0,07$. Pakkasan purevuutta käytetään tavallisesti, kun ilmanlämpötila on alle 14 °C eli sen viilentävää vaikutusta ei huomata kesällä (Kuva 3-8). Helteen tukaluutta puolestaan lasketaan lämpötilan ollessa yli 14,5 °C ja säteilyn vaikutus huomataan vasta, kun saapuvan säteilyn suuruus on yli 50 W/m² eli ne nostavat lämpötilan tuntua lähinnä loppukeväästä ja kesällä (Jussi Kaurola, Ilmatieteen laitos, henkilökohtainen tiedonanto).



Kuva 3-8. "Tuntuu kuin" -lämpötilan (°C) ja lämpötilan (°C) kuukausikeskiarvot vuosina 2015 – 2018 Etelä-Suomen rannikolla sijaitsevalla paikkakunnalla.

Pakkasan purevuus -indeksi perustuu tuulen ja kosteuden aiheuttamaan viilentävään vaikutukseen, kun lämpöä johtuu iholta (Randall, 1995). Tuulen, auringon säteilyn, ilman kosteuden ja muidenkin sääsuureiden vaikutuksia niin ulkoilman lämpötilan tuntuun kuin lämmönkulutukseen on tutkittu aikaisemmin. Seuraavassa osiossa käsitellään aihetta

aikaisempien tutkimusten perusteella. Tuntuu kuin -lämpötilan ja kaukolämmön kulutuksen väliseen yhteyteen palataan vielä myöhemmin kokeellisessa osuudessa.

4. Aikaisempi tutkimus aiheesta

Sään vaikutusta kaukolämmitykseen on tutkittu aikaisemminkin, tosin melko insinöörimäisestä näkökulmasta. Kwak ym., (2012) ennustivat lämmöntarvetta sääennusteiden ja auringonsäteilytietojen pohjalta. Sääsuureiden huomattiin vaikuttavan lämmöntarpeeseen, mutta toimivan mallin muodostaminen oli vaikeaa. Uudessa Seelannissa tehdyssä tutkimuksessa pyrittiin ennustamaan toimistorakennusten lämmönkulutusta historiallisia säähavaintoja käyttäen lineaarisen regressiomallin avulla (Safa ym., 2014). Tutkimuksen perusteella lineaarisen mallin luominen hyväksyttävien virhemarginaalien puitteissa oli mahdollista, mutta tarpeeksi tarkan havaintoaineiston saaminen aiheutti ongelmia.

Ruotsissa tehdyn tutkimuksen mukaisesti (Werner, 1984) ulkolämpötila selittää n. 60 % kaukolämmön tarpeesta. Sen sijaan tuulen vaikutuksen arvioitiin vaihtelevan 1 – 4 % välillä ja auringonsäteilyn vaikutuksen 1 – 5 % välillä. Puolassa tehdyssä tutkimuksessa huomioitiin ensin tuulen ja auringonsäteilyn vaikutukset ulkoilman lämpötilaan, jonka seurauksena niiden todettiin vaikuttavan myös kaukolämmön tarpeeseen (Wojdyga, 2008). Tutkimuksen perusteella auringonsäteilyn vaikutus kaukolämmön tarpeeseen on tuulen vaikutusta suurempi. Tuulen vaikutus havaittiin olemattomaksi, jos tuulen nopeus oli alle 2 m/s. Sen sijaan tuulen nopeuden kasvaessa yli 10 m/s sen aiheuttamat lämpöhäviöt kasvoivat merkittävästi. Tuulen nopeuden ollessa välillä 5 – 10 m/s tuulen nopeuden kasvu 1 m/s vaikutti keskimäärin yhtä paljon kuin lämpötilan lasku 3 - 4 °C asteen verran (Wojdyga, 2008). Kuten myös Puolassa, Suomessa kovimmat tuulen nopeudet havaitaan yleensä juuri talviaikaan (Kuva 3-4).

Aiemmin tehtyjen tutkimuksien perusteella tuulen on havaittu vaikuttavan rakennusten lämmönkulutukseen kahdella tavalla. Ensinnäkin tuulen nopeuden kasvaessa ulkoseinien lämpökonvektiokerroin (α , ”heat convection coefficient”) kasvaa. Normaalisti konvektiokertoimen vaikutus rakennusten lämmönkulutukseen on pieni, mutta rakennusmateriaalista riippuen se voi kasvattaa lämpöhäviöitä jopa 20 - 30 % verran. Voimakkaan tuulen on myös havaittu vaikuttavan ulkoseinien ja sisätilan väliseen paine-eroon, sillä sen seurauksena seinien ulkopuolelle muodostuu hetkellisesti korkeampi ilmanpaine (Wojdyga, 2008). Paine-eron pyrkiessä tasoittumaan virtaa seinän ulkopuolelta yhä enemmän kylmää ilmaa rakennuksen sisälle. Kirjallisuudessa tästä on käytetty termiä ”luonnollinen tuulettuminen” (natural ventilation).


Auringon säteilyn vaikutus lämmitykseen määrään on luonnollisesti pieni osittain myös siitä syystä, että lämmitystarpeen ollessa huipussaan talvisin säteilyn määrä on vähäistä. Samaisen tutkimuksen mukaan Varsovan säteilymäärä vuonna 2004 oli $3397 \text{ MJ}/\text{m}^2$. Tästä kuitenkin loka-maaliskuun välisen ajan, jolloin myös lämmityksen tarve on suurin, osuus oli ainoastaan $702 \text{ MJ}/\text{m}^2$. Näinkin vähäisen säteilyn määrän havaittiin vähentävän lämmitystarvetta, mutta tutkimuksessa painotettiin rakennuksen maantieteellisen sijainnin vaikutusta. Esimerkiksi joulukuussa etelään päin osoittavan seinän säteilymäärä oli kaksinkertainen verrattuna itään päin osoittavaan seinään (Wojdyga, 2008).

5. Sääennustaminen

Tässä pro gradu -tutkielmassa tutkin kaukolämmön ja sään välistä yhteyttä ainoastaan historiallisia säähavaintoja käyttäen. Sähavaintojen kerääminen on tärkeä osa sääennustusta ja erityisen tärkeää sääennustuksen luotettavuuden takaamiseksi. Havaintojen perusteella saadaan realistista tietoa ilmakehän nykytilanteesta aina ilmakehän ylärajalle asti. Tässä kappaleessa käsitelläänkin aluksi havaintoverkoston ja havaintojenkeruuta. Tutkielman tarkoitus on kuitenkin nähdä, vaikuttavatko eri sääsuureet, kuten tuuli, kosteus tai auringonsäteily kaukolämmön tarpeeseen niin paljon, että ne tulisi huomioida etukäteen lämmöntarpeen suuruuden arvioinnissa lämpötilaennusteen lisäksi. Sen vuoksi lämmöntarpeen ennustamisen kannalta on tärkeä tietää, kuinka luotettavia sääennusteita on saatavilla ja mitkä asiat vaikuttavat sääennusteiden paikkansapitävyyteen. Johdatuksena aiheeseen tässä luvussa käsitellään itse sään ennustamisen perusperiaatteita, kuten ilmakehän alkutilan määrittystä data-assimilaation avulla, ennustemallin aikaintegrointia sekä ennustusmallien ominaisuuksia että luokittelutapoja. Kappaleessa käsitellään myös Suomessa yleisesti käytettyjä säämalleja ja niiden ominaisuuksia. Kaukolämpöennusteiden perustuessa sääennusteisiin on myös hyvä muistaa sääennusteiden ajalliset rajoitteet niiden kyvyssä ennustaa eri sääilmiöitä, jonka vuoksi kappaleen lopussa käsitellään hyvin yleisellä tasolla sääennusteiden paikkansapitävyyttä Suomen ilmasto-olosuhteissa.

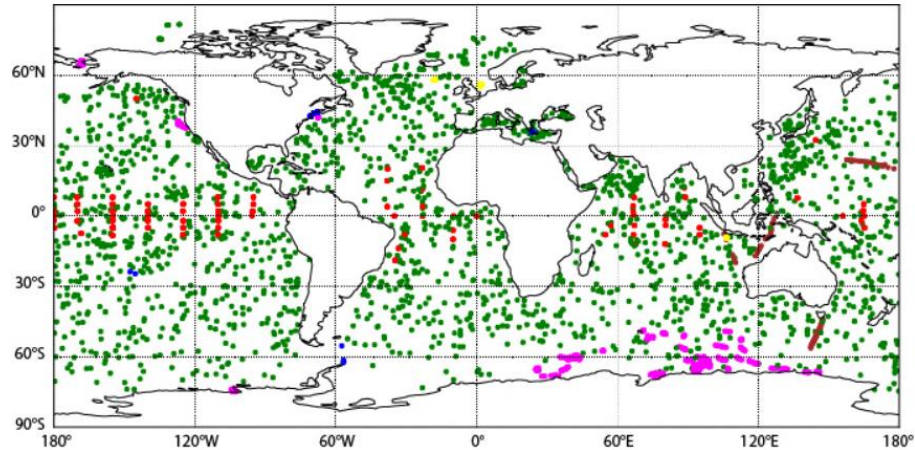
5.1 Havaintoverkosto

Havainnot ovat välttämätön osa sään ennustuksessa oikeanlaisen lähtötilanteen muodostamiseksi. Havaintoja ilmakehästä saadaan globaalista havaintojärjestelmästä, jossa havaintoja tehdään niin ilmakehässä, maalla kuin merillä (Alatalo, 2009). Havaintojärjestelmät voidaan jakaa in situ -havaintojärjestelmiin ja kaukohavaintojärjestelmiin. In situ -mittaukset tehdään aina kosketuksessa havaittavaan kohteeseen eli ne sopivat eritoten hyvin maanpinnan läheisiin mittauksiin. Maalla in situ -havaintoja saadaankin sekä miehitettyiltä että automaattisilta sääasemilta. Yli 11 000 pintasääasemaa ovat tärkeässä osassa maailmanlaajuisesta säähavaintoverkoston (Kuva 5-1). Asemilla mitataan mm. ilmapainetta, tuulen suuntaa ja -nopeutta, ilman lämpötilaa ja kosteutta (World Meteorological Organization). Havaintoja mitataan yleensä vähintään tunnin välein, mutta joillakin asemilla mittausväli on kolme tuntia. Havainnot viestitetään reaaliajassa (World Meteorological Organization).



Kuva 5-1. Pintahavaintoasemien maantieteellinen jakauma ja perustamisvuosi (Hashemi, 2009)

Merellä in situ -havaintoverkosto kattaa niin reittiliikennelaivojen, kiinteiden ja ankkuroiden alustojen kuin ajelehtivien poijujen välityksellä tehdyt mittaukset (Kuva 5-2). Lisäksi havaintoja tehdään saarilla. Koska in situ -mittausten on oltava kosketuksessa mitattavan asian kanssa, sopivat ne luonnollisesti maanpinnan läheisiin mittauksiin ja takaavat tarkkoja, luotettavia ja yksikäsitteisiä mittaustuloksia (Nousiainen ja Sundström, 2014). Mittausdataa saadaan kuitenkin myös rajakerroksesta ja yläilmakehästä. Rajakerroksessa havaintoja tehdään havaintotornien ja mittausmastojen välityksellä, joilla mitataan mm. lämpötilaa, tuulen nopeutta ja -suuntaa, kosteutta ja ilmanpainetta aina 150 m korkeudelle asti. Mittalaitteet sijoitetaan yleensä useammalle korkeudelle, joten mastojen ja tornien avulla saadaan tietoa sääsuureiden muutoksesta korkeuden mukana. Yläilmakehässä havaintoja tehdään säähavaintopallojen kuljettamien radioluotainten ja lentokoneiden sisältämien mittalaitteiden avulla (Alatalo, 2009).



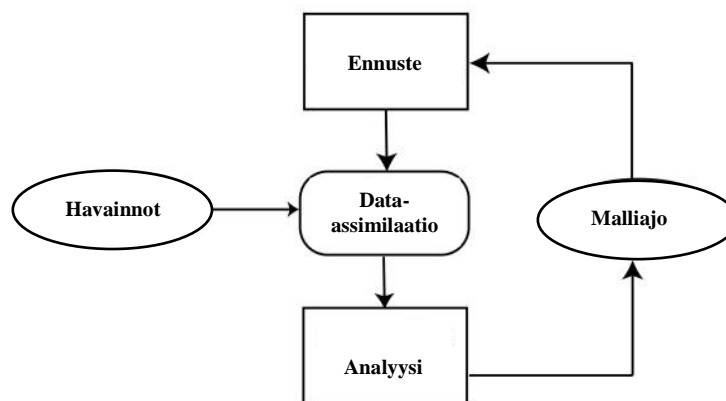
Kuva 5-2. Tyypillinen mereltä saatavien in situ -havaintojen alueellinen kattavuus. Vihreät pisteet kuvaavat kelluvilta alustoilta, punaiset pisteet kiinteiltä alustoilta, ruskeat pisteet laivoilta, siniset pisteet risteilijöiltä, violetit merinisäkkäihin kiinnitetyistä mittalaitteista ja keltaiset pisteet merenpinnan alapuolelta saatava havaintoja (ECMWF, 2019).

Vaikka in situ -havaintojärjestelmä on varsin kattava, sen avulla tehtyjen havaintojen perusteella ei kuitenkaan saada tietoa koko ilmakehän säätilasta. Havaintojen saaminen on haastavaa ja havaintoverkko liian harva erityisesti vaikeasti saavutettavissa paikoissa, kuten aavikoilla, jäätiköillä, vuoristoissa ja valtamerillä. Kaukohavaintojärjestelmä täydentääkin hyvin in situ -havaintojärjestelmää (Nousiainen ja Sundström, 2014). Tärkeimmät kaukomittauslaitteet ovat tekokuut eli sääsatelliitit ja säätutkat. Muita kaukomittauslaitteita ovat akustinen tutka eli SODAR, lasertutka eli LIDAR ja erilaiset radiometrit. Akustisen tutkan toiminta perustuu ääniaaltojen kulkuun, mutta muiden kaukomittauslaitteiden toiminta perustuu sähkömagneettisen säteilyn kulkuun (Nousiainen ja Sundström, 2014).

Kaukomittalaitteet voidaan jakaa passiivisiin ja aktiivisiin niiden toimintaperusteen mukaan. Aktiiviset laitteet, kuten säätutka lähettävät sähkömagneettista säteilyä, jonka kaiku heijastuu takaisin mittalaitteeseen. Sen sijaan passiiviset laitteet, kuten esimerkiksi suurin osa sääsatelliittien mittalaitteista ainoastaan vastaanottavat maanpinnasta ja ilmakehästä heijastuneen tai emittoituneen säteilyn signaalin. Sääsatelliiteista saatavat havainnot ovat ehdottomasti tärkeimpiä säänennustuksen kannalta ja muodostavat n. 98 % ennustuksessa käytetyistä havainnoista (Alatalo, 2009).

5.2 Ennusteen alkutilan määrittäminen data-assimilaatiomenetelmällä

Luotettavan sääennustuksen aikaansaamiseksi mallille syötetyn alkutilan on vastattava mahdollisimman tarkasti sen hetkistä ilmakehän tilaa. Realistinen ja luotettava kuva saadaan ennen kaikkea luvussa 5.1 kuvattujen säähavaintojen ja mittausten pohjalta. Erityisesti sääsatelliittien käytön ansiosta on havaintoja saatavilla kattavasti ympäri maapalloa. Havaintoverkosto ei kuitenkaan ole vielä tarpeeksi tiheä, jotta se yksin riittäisi luomaan täydellisen kuvan ilmakehän toiminnasta. Tämän vuoksi sääennusteen alkutila muodostetaan data-assimilaatiomenetelmän avulla, joka perustuu ennusteen alkutilan luomiseen edellisen malliajon tulosten ja ilmakehän sen hetkisten havaintojen perusteella (Kuva 5-3).



Kuva 5-3. Havaintojen ja edellisen ennusteen tulosten yhdistäminen data-assimilaatiomenetelmän avulla (Kostelich ym., 2011).

Data-assimilaatio on laskennallinen menetelmä, jota käytetään säänennustamisen lisäksi myös muiden erilaisten havaintotietojen yhdistämiseen. Säänennustuksessa data-assimilaatiomenetelmää käytetään vallitsevan säätilan analyysin luomiseen (Eresmaa). Analyysi muodostetaan laskemalla optimaalinen keskiarvo pienimmän neliösumman menetelmän avulla säämallin antamalle ennusteelle ja kyseisen ajanhetken säähavainnoille. Vallitsevan säätilan analyysi toimii puolestaan alkutilana seuraavalle ennustejolle, josta saatua ennustetta täydennetään jälleen ilmakehän sen hetkellä havainnoilla data-assimilaatiomenetelmällä (ECMWF A). Näin muodostuu taas uusi analyysi, jota voidaan edelleen käyttää alkutilana seuraavalle malliajolle jne. (Kuva 5-3). Sen lisäksi, että data-assimilaation tuottama analyysi pyrkii luomaan mahdollisimman tarkan alkutilan seuraavaa malliajoa varten, se on myös

itsessään tärkeä meteorologian työkalu ilmakehän hetkellisen tilan kuvaamisessa (Bouttier ja Courtier, 1999).

5.3 Ennustusmallien toiminta

Sääennustusmallit koostuvat ilmakehän käyttäytymistä sääteleviä fysiikan lakeja kuvaavista yhtälöistä. Ilmakehän virtauksen käyttäytymistä kuvataan seuraavan perus- eli primitiiviyhtälöryhmän avulla:

$$\frac{d\vec{V}}{dt} = -\frac{1}{\rho}\nabla p - 2\vec{\Omega} \times \vec{V} - \vec{g} + \vec{F} \text{ (Liikemäärän säilymlaki)} \quad (5.1)$$

$$\frac{\delta\rho}{\delta t} = -\nabla \cdot (\rho\vec{V}) \text{ (Massan säilymlaki)} \quad (5.2)$$

$$c_p \frac{dT}{dt} - \frac{1}{\rho} \frac{dp}{dt} = Q \text{ (Energian säilymlaki)} \quad (5.3)$$

$$p = \rho RT \text{ (Ihannekaasun tilanyhtälö)} \quad (5.4)$$


$$\frac{\delta\rho q}{\delta t} = -\nabla \cdot (\rho q\vec{V}) + \rho S \text{ (Massan säilymlaki vesihöyrylle)} \quad (5.5)$$

Perusyhtälöryhmän (5.1–5.5) avulla pyritään laskemaan ilmakehän tilanmuuttujien, eli kolmiulotteisen tuulennopeusvektorin \vec{V} , ilmanpaineen p , kosteuden q , tiheyden ρ ja lämpötilan T arvot/muutokset kussakin laskentapisteessä (Järvinen, 2015). Yhtälöissä esiintyy lisäksi coriolisvoiman suuruuteen vaikuttava maapallon pyörimisnopeus $\vec{\Omega}$, putoamiskiihtyvyys \vec{g} , ominaislämpökapasiteetti c_p , kitkavoima \vec{F} sekä lämmön diabaattinen nettolähde Q että vesihöyryn nettolähde S . Primitiiviyhtälöt ovat yhtälöä (5.4) lukuun ottamatta prognostisia, eli ne sisältävät tilanmuuttujien aikaderivaattoja. Ihannekaasun tilanyhtälö (5.4) puolestaan on diagnostinen eli tilanmuuttujat kuvaavat vain yhtä ajanhetkeä (Järvinen, 2015).

Ilmakehän virtausyhtälöistä koostuvat mallit pyrkivät jäljittelemään mahdollisimman tarkasti niin ilmakehän termodynaamista tilaa kuin virtauskenttää. Niiden avulla pyritään luomaan kattava ja ajassa etenevä kuva ilmakehän tilasta. Numeerisen ratkaisemisen mahdollistamiseksi differentiaalimuotoiset yhtälöt on diskretisoitava eli tilanmuuttujat esitetään hilapisteissä. Hilapistemalleissa ilmakehä jaetaan vaaka- ja pystysuunnassa laskentapisteisiin, jotka yhdessä muodostavat kolmiulotteisin hilaruudukon (Vallinheimo, 2016). Mallin hilaväli tarkoittaa kahden laskentapisteen välistä etäisyyttä ja se määrittää myös, minkä kokoisia ilmiöitä tietyllä mallilla voidaan ennustaa: mitä lyhyempi hilaväli on, sitä tarkempi on mallin paikallinen erotuskyky.

Hilapistemallien lisäksi on olemassa spektrimalleja, jotka kuvaavat ilmakehää aaltosarjoina (Holopainen ym., 2008). Yhtälöryhmien diskretisoinnin jälkeen voidaan niiden arvoja laskea aika-askel kerrallaan, kunhan suureiden alku- ja reuna-arvot tunnetaan.

Operatiivinen eli jatkuva laskennallinen sään ennustaminen koostuu peräkkäisistä malliajoista. Edellisen malliajon muodostamaa ennustetta voidaan tarkentaa data-assimilaatiomenetelmän avulla vastaamaan paremmin sen hetkistä ilmakehän tilaa, kuten luvussa 5.1 kuvattiin, ja uusi analyysi toimii puolestaan alkutilana seuraavalle malliajolle. Ennustusmallista riippuen malliajot ajetaan 2-4 kertaa vuorokauden aikana, joten ennusteet ehtivät muuttua useamman kerran päivän aikana. Kuva 5-4 havainnollistaa sään ennustusta tilanteessa, jossa uusi ennusteaajo tehdään aina kuuden tunnin välein.



Kuva 5-4. Sään ennustaminen mallilla, jolla ennusteaajo suoritetaan kuuden tunnin välein (Ilmatieteen laitos, 2015a).

Mallien vaakasuuntaisen hilavälin lisäksi myös pystysuuntainen hilaväli ja mallin aika-askel vaikuttavat siihen, minkä kokoluokan sääilmiöitä tietyllä mallilla on mahdollista ennustaa. Sääilmiöitä luokitellaan niiden ajallisen ja paikallisen ulottuvuuden mukaisesti. Globaalit ilmiöt, kuten planetaariset ilmakehän aallot, vaikuttavat jopa 4 000 – 20 000 km kokoisella alueella ja ajallisesti kestävät noin viikosta kahteen (Tuuliatlas B). Synoptisen mittakaavan ilmiöihin luokitellaan sekä matala- ja korkeapaineet eli syklonit ja antisyklonit että matalapainetoimintaan liittyvät rintamat. Synoptisen mittakaavan ilmiöt kestävät tyypillisesti päivästä viikkoon ja niiden kokoluokka vaihtelee 200 km - 4 000 km välillä. Mesoskaalan ilmiöihin kuuluvat kokoluokaltaan n. 10 km – 200 km kokoiset ja tunnista päivään kestävät ilmiöt, kuten paikalliset

puuskarintamat, sadenauhat sekä meri-, maa- ja rinnetuuli (Tuuliatlas B). Tämän ja tätä pienemmän mittakaavan sääilmiöillä on suuri vaikutus tietyn paikkakunnan säähän ja siksi ne pyritään mallintamaan mahdollisimman tarkasti. Näin pienen mittakaavan ilmiöiden ennustaminen on kuitenkin haastavaa mallien hilavälien ja ajallisen tarkkuuden puitteissa.

Mallin erotuskykyä pienikokoisemmat ilmiöt, kuten lyhyt- ja pitkäaaltoisen säteilyn kulku, vesihöyryn tiivistyminen ja konvektio sekä mm. rajakerroksen turbulenssi pyritään esittämään parametrisoinnin avulla. Parametrisointia varten säämalleihin on lisättävä ns. fysiikkaosuus, jolloin primitiiviyhtälöiden kuvaaman virtausdynamiiikan lisäksi saadaan ratkaistua myös mallin hilaväliä pienempien fysikaalisten ilmiöiden nettovaikutukset hilapisteikössä ratkaistujen tilanmuuttujien aikakehitykseen (Järvinen, 2015).

5.4 Sääennustusmallit

Sääennustusmallit voidaan karkeasti jakaa eri ryhmiin niiden kattaman mallinnusalan perusteella ja ennusteajojen ajallisen keston mukaisesti. Mallinnusalan perusteella mallit jaetaan sekä koko maapallon ilmakehän kattaviin, globaaleihin malleihin että rajoitetun alueen malleihin eli LAM-malleihin. Ennustettavan ajan puolesta malliajot taas luokitellaan erittäin lyhyistä alle yhden vuorokauden mittaisista ennusteista pitkiin, yli 15 vuorokautta kestäviin ennusteisiin (Ilmatieteen laitos, 2015c). Isot, laskennallisesti raskaat ja paljon tietokoneresursseja vievät globaaleilla malleilla tehtävät ennusteet ovatkin yleensä kestoaltaan joko pitkiä tai keskipitkiä, 3 – 15 vuorokauden mittaisia malliajoja. Sen sijaan pienemmälle alueelle rajoittuvien ja huomattavasti paremman paikallisen tarkkuuden omaavien LAM-mallien ennusteajot ovat ajalliselta kattavuudeltaan joko erittäin lyhyitä tai lyhyitä, 1 – 3 vuorokauden ennusteita (Ilmatieteen laitos, 2015c).


Yleisenä sääntönä voidaan pitää, että mitä pienempää aluetta malli ennustaa ja mitä lyhyempi ajallinen ennuste on, sen tarkempi kuva ilmakehän tilasta tietyllä hetkellä saadaan. Tämä rajoittaakin yleisesti ottaen sääennusteiden pituuksia. Kuten Holopainen ym. (2008) toteavat sääennusteiden pituuksista: Kymmentä vuorokautta pidempää sääennustetta ei kannata tehdä, sillä ilmakehä käyttäytyy kaoottisesti. Sääennustamisen kannalta tämä tarkoittaa sitä, että kaksi hyvin samankaltaista lähtötilannetta voivatkin kehittyä ajan kuluessa niin erilaisiin suuntiin, että lopulta niissä ei havaita mitään yhtäläisyyttä (Ruosteenoja, 1996). Näin ollen pienikin virhe mallin alkutilan määrittämisessä voi ennustusajan myötä kääntää mallin kuvaaman sään kehityksen

aivan toisenlaiseksi kuin mitä oikeasti havaittiin. Ilmakehän kaoottisuuden ja huonosti määritetyn malliajon alkutilan lisäksi mallien erilaiset systemaattiset virheet aiheuttavat epävarmuutta ilmakehän käyttäytymisen kuvaamisessa.

Globaalit eli koko maapallon ilmakehää kuvaavat mallit ovat välttämätön osa säänennustusta. Koska niiden mallinnusala kattaa koko ilmakehän (Kuva 5-5), saadaan niiden avulla ns. reuna-arvot ajallisesti ja paikallisesti tarkemmille rajoitetun alueen malleille. Globaaleilta malleilta saadaan siis ikään kuin tieto, miten ilmakehä käyttäytyy rajoitetun alueen mallien reunoilla malliajosten aikana (Ilmatieteen laitos, 2015b). Euroopan keskipitkien ennusteiden keskuksen eli ECMWF:n (”European Centre for Medium-Range Weather Forecast”) globaali malli on yksi edistyneimmistä koko maapallon ilmakehän kiertoliikkeen kattavista malleista. ECMWF:sta saadut reuna-arvot ovat laajalti käytössä ympäri maailmaa ja niitä käytetään myös rajoitetun alueen mallien reuna-arvoina Suomessa. Alempana esitellään tarkemmin niin ECMWF:n globaalin mallin kuin Suomessa yleisesti käytettyjen rajoitetun alueen mallien HIRLAM:n ja HARMONIE:n ominaisuuksia.


5.4.1 ECMWF:n globaali malli

ECMWF:n mallilla tuotetaan 12 tunnin välein 52 ennusteaikaa: tarkemman resoluution mallilla tuotettu ns. HRES-ennuste sekä 51:stä karkeamman resoluution mallilla tehdystä ajosta koostuva parviennuste (ECMWF D). HRES-ennusteen alkutila pyrkii vastaamaan mahdollisimman tarkasti sen hetkisiä ilmakehän havaintoja. Kaksi kertaa vuorokaudessa, 0 UTC ja 12 UTC, ajettavan malliajon pituus on 10 vuorokautta. HRES-ennusteen vaakasuora resoluutio on 9 km ja pystysuunnassa mallinnustasoja on 137 kappaletta, joista ylin vastaa 0,01 hPa:n painepintaa (ECMWF B). Karkeamman resoluution ennusteista vain yhden alkutila pyrkii HRES-ennusteen tavoin vastaamaan mahdollisimman tarkasti ilmakehän sen hetkistä tilaa. Muut parviennusteen karkeamman resoluution malliajot poikkeavat toisistaan joko hieman erilailla määritetyn ennusteen alkutilan tai mallin ominaisuuksien puolesta. Ennusteiden vaakasuuntainen resoluutio on 18 km ja pystysuunnassa tasoja on 91 kappaletta, joista ylin vastaa 0,01 hPa painepintaa. Malliajon pituus on 15 vuorokautta (ECMWF B).



Kuva 5-5. Kaaviokuva globaalin säämallin mallinnusalasta ja jaottelusta kolmiulotteiseen hilaruudukkoon (VAS3K, 2018).

Parviennusteiden avulla on mahdollista nähdä, miten mallien erilaiset systemaattiset virheet vaikuttavat ilmakehän käyttäytymisen kuvaamisessa ja kuinka paljon virheellisesti määritelty alkutila vaikuttaa malliajon tuloksen (kuva 5-6; Siiskonen, 2015). Näin saadaan tietoa ennusteen epävarmuudesta ja ennusteesta tulee luotettavampi. Jotta ennusteeseen liittyvistä epävarmuuksista saataisiin todenperäinen kuva, täytyy myös parviennusteiden jäsenten alkutiloihin lisättyjen virheiden vastata mahdollisimman tarkasti mallin alkutilaan liittyviä epävarmuuksia (ECMWF C). Parviennusteita käytetään säänennustamisen lisäksi myös muiden kaoottisten systeemien käyttäytymisen ennustamisessa, sillä niiden avulla on mahdollista havaita ennusteen erilaisia mahdollisia tuloksia ja myös kaikista todennäköisen lopputulos.

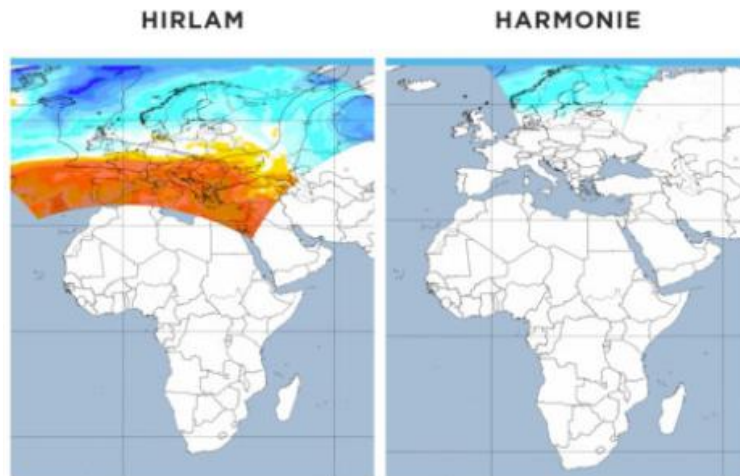


Kuva 5-6. Alkutilaltaan erilaisten ennusteiden kehittyminen malliajon kuluessa (ECMWF, 2017).

5.4.2 HIRLAM

HIRLAM (”High Resolution Limited Area Model”) on kansanvälisen HIRLAM-konsernin kehittämä rajatun alueen tarkka säämalli. Konserni on perustettu vuonna 1985 ja siihen kuuluu 10 eurooppalaista meteorologian instituuttia, joista Ilmatieteen laitos on yksi (HIRLAM, 2016). HIRLAM-ohjelman tarkoituksena on luoda käyttäjilleen niin lyhyitä kuin erittäin lyhyitä, korkealaatuisia sääennusteita ja taata ennen kaikkea luotettavia ennusteita poikkeavista sääilmiöistä yleisen turvallisuuden takaamiseksi.

HIRLAM-mallin nykyisen version vaakasuuntainen hilaväli on 7.5 km ja pystysuunnassa tasoja on 65 kappaletta. Ennuste ajetaan 4 kertaa vuorokaudessa: UTC 00, 06, 12 ja 18 aikaan (Ilmatieteen laitos D). Malliajon kesto on 48 tuntia. HIRLAM:n mallinnusala kattaa Euroopan lisäksi myös Pohjois-Atlantin alueen (kuva 5-7).



Kuva 5-7. HIRLAM- ja HARMONIE-mallien kattamat alueet (Vallinheimo, 2016).

5.4.3 HARMONIE


HARMONIE on HIRLAM-konsernin ja ranskalaisen ALADIN-konsernin yhdessä kehittämä ei-hydrostaattinen, rajatun alueen säämalli, jonka vaakasuuntainen resoluutio on jopa 2.5 km. HARMONIE:n kehitys alkoi vuonna 2006 ja vuodesta 2011 lähtien HIRLAM-konserni onkin keskittynyt pääosin HARMONIE:n kehittämiseen. Malli kattaa Skandinavian alueen, Baltian alueen ja Norjanmeren (kuva 5-7; Vallinheimo, 2016). HIRLAM-mallin tapaan myös HARMONIE-mallilla ajetaan uusi ennuste neljä kertaa vuorokaudessa, UTC 00, 06, 12 ja 18 aikaan. Malliajon pituus on 66 tuntia (Avoindata.fi, 2019).

5.5 Ennusteiden osuvuus Suomessa

Yleisesti ottaen sääennusteiden osuvuus on parantunut huomattavasti, johtuen niin meteorologien osaamisesta, paremmista säänennustusmalleista ja havaintomenetelmistä kuin tietokoneiden jatkuvasta kehitymisestä (Ilmatieteen laitos, 2018b). Esimerkiksi Suomessa yhden vuorokauden lämpötilaennuste osuu n. 90 % tarkkuudella. Käytännössä tämä tarkoittaa sitä, että päivälämpötilat eli lämpötilat aikavälillä 06 UTC – 18 UTC osuvat maksimissaan $\pm 2\text{ }^{\circ}\text{C}$:n päähän ennustetusta lämpötilasta ja yölämpötilat $\pm 3\text{ }^{\circ}\text{C}$:n päähän. Haasteita säänennustamiselle Suomessa aiheuttaa sääolojen suuri vaihtelevuus. Sään nopeat muutokset, kuten esimerkiksi sään mahdollisen selkeneminen talviaikaan heikentävät ennusteiden tarkkuutta Suomen ilmastolosuhteissa.

Sääilmiön ajallisen keston ja kokoluokan lisäksi myös vuodenaika vaikuttaa sääilmiöiden ennustettavuuteen (Ilmatieteen laitos, 2018a). Esimerkiksi vallitsevaa säätyyppiä eli korkea- ja matalapaineiden virtaa tai kylmän purkausta on mahdollista ennustaa n. 6 – 12 vuorokauden päähän. Matalapaineiden ja sadealueiden reitit pystytään ennustamaan kuitenkin vain 3 – 6 vuorokauden päähän. Tuulen suunta ja -nopeus riippuvat puolestaan matalapaineiden ja rintamien reiteistä, joten tarkat ennusteet ovat mahdollisia vasta 2 – 5 vuorokautta aikaisemmin.

Sateen luonne ja vuodenaika vaikuttavat sadealueiden ja -määrän ennustukseen. Rintamasateita on mahdollista ennustaa n. 2 vuorokautta aikaisemmin, mutta sen sijaan kesäisiä sadekuuroja on lähes mahdotonta ennustaa tarkasti etukäteen. Sademäärä ja sateen todennäköisyys eivät myöskään riipu suoraviivaisesti toisistaan, josta hyvänä esimerkkinä toimivat juurikin kesäiset sadekuurot: kuuron tarkkaa sijaintia on vaikea ennustaa, joten tietylle paikalle ja ajalle ennustettuun sademäärään saattaa tulla suurta heittoa. Kesällä korkeapaineita lukuun ottamatta sääilmiöiden lyhyt ajallinen kesto ja pieni paikallinen kokoluokka vaikeuttavat ennustamista (Ilmatieteen laitos, 2012a). Korkeapaineiden vallitessa auringon lämmitys ja korkeapaineisiin liittyvä ilman laskeva liike hävittävät tyypillisesti pilvet, joten sade-, pilvisyys- ja lämpötilaennusteet osuvat hyvin kohdalleen.



Kuva 5-8. Pilvisyyden vaikutus lämpötilan vuorokausivaihteluun eri kuukausina Helsingin Kaisaniemessä (Ilmatieteen laitos C).

Ulkoilman lämpötila voidaan ennustaa keskimäärin 4 – 8 vuorokauden päähän. Lämpötilaennusteen onnistuminen riippuu kuitenkin pilvisyysennusteen tarkkuudesta, sillä pilvet vaikuttavat sekä auringon säteilyn pääsyyn maanpinnalle että yölliseen säteilyjäähdytymiseen maanpinnalta. Pilvisuus vaikuttaa voimakkaasti vuorokauden aikaiseen lämpötilan vaihteluun (kuva 5-8). Esimerkiksi talviaikaan pilvisellä säällä vuorokauden aikainen lämpötilan vaihtelu on lähes olematonta, mutta pilvettömillä alueilla vuorokauden lämpötilaerot puolestaan voivat olla suuria. Talviöinä ilmakehän vastasäteily on heikkoa ja maanpinnan säteilyjäähdytymisen voimakasta, minkä seurauksena ulkoilman lämpötila voi pilvettömällä alueella olla useita asteita matalampi kuin pilvisellä alueella. Paikallisiin lämpötilaeroihin vaikuttavat pilvisyyden lisäksi myös maaston topografia, rannikon läheisyys ja paikalliset tuuliolosuhteet.

Talvisten korkeapaineiden vallitessa pilvisyyttä ja sitä kautta ilman lämpötilaa on vaikea ennustaa. Auringosta saatava säteilyenergia on talvisin niin vähäistä, että korkeapaineisiin liittyvästä ilman laskevasta liikkeestä huolimatta se ei välttämättä riitä pilvien häivyttämiseen (Ilmatieteen laitos, 2012b). Talvella lämpötilan ennustaminen on helpompaa Suomen kuullessa matalapaineen alueeseen. Talvisten matalapaineiden vallitessa runsaasta pilvisyydestä johtuen auringonsäteilyä saadaan maanpinnalle vähän ja myös yöllinen säteilyjäähdytymisen on vähäistä (Kuva 5-8). Lämpötila ei juuri vaihtelee vuorokauden aikana eikä paikallisia lämpötilaeroja havaita, kuten talvisten korkeapaineiden aikaan. Talvisten matalapaineiden suurin haaste on sadealueiden reittien tarkka ennustaminen ja sateen tarkka ajoitus.

6. Kaukolämmön tuotannon riippuvuus sääolosuhteista

Tässä osiossa on tarkoitus tutkia, mitkä tekijät vaikuttavat kaukolämmön kulutukseen ja onko kulutuksen tarvetta mahdollista selittää eri sääparametrien avulla. Lämmön tuotantotehon (MW) ja eri sääsuureiden välisiä yhteyksiä etsitään ensin korrelaatioanalyysin avulla. Lisäksi eri ajanjaksoille pyritään muodostamaan myös regressiomallit, joissa huomioidaan ulkolämpötilan lisäksi ns. sosiaalinen vaikutus. Regressiomallit on muodostettu erikseen koko vuoden kattavalle ajanjaksolle, ”lämmityskaudelle” eli loka-maaliskuulle sekä kevät- (maalis-toukokuu) että kesäkuukausille (kesä-elokuu).

Osiassa käytetty lämmöntuotanto kuvaa Etelä-Suomessa sijaitsevan kaupungin lämmönkulutusta vuosina 2015 – 2018 (Pöyry Finland Oy, 2019). Lämmönkulutuksen tarve vaikuttaa siihen, millä teholla (MW) lämpöä tuotetaan ja tämän vuoksi lämmöntuotantomääriä on käsitelty nimenomaan tuotantotehon avulla. Luottamussyistä tuotantotehon tarkkoja määriä ei voida kirjoittaa ja tuotantotehojen suuruudet on joko jätetty kokonaan merkitsemättä kuvaajien y-akseleille tai ne on annettu prosentteina maksimitehosta. Myöskään muuttujien välisiä lineaarisia yhtälöitä ei ole esitetty vaan riippuvuudet on annettu selitys- ja korrelaatiokertoimien avulla. Kaukolämmön tuotantotiedoista on pyritty poistamaan virheelliset arvot, kuten selkeästi havaittavissa olevat mittausvirheet. Datan toimituksessa on myös havaittavissa jonkin verran katkoja, jonka seurauksena esimerkiksi heinäkuun 2016 tuotantotiedot puuttuvat kokonaan. Puuttuvien ajanjaksojen säähavaintotietoa ei ole myöskään käytetty myöhemmin korrelaatioiden ja regressiomallien määrittämisessä. Säähavaintotiedot ovat peräisin samalta paikkakunnalta lukuun ottamatta säteilyhavaintoja, jotka ovat Helsingin Kumpulasta (Ilmatieteen laitos A).

6.1 Korrelaatio- ja regressioanalyysi

Sekä korrelaatio- että regressioanalyysi ovat tilastollisessa matematiikassa käytettyjä työkaluja, joilla pyritään kuvaamaan kahden tai useamman muuttujan välisiä riippuvuuksia. Korrelaatioanalyysissä ei välitetä, kumpi muuttujista on syy ”X” ja kumpi seuraus ”Y” (Heino ym., 2012). Regressioanalyysissä yhden muuttujan ”Y” käyttäytymistä selitetään muiden muuttujien ” X_n ” avulla. Muuttuja Y on ns. selitettävä eli riippuva muuttuja. Loput muuttujat X_1 , X_2 ..., X_n ovat selittäviä eli riippumattomia muuttujia, joidenka välillä ei saa olla voimakkaita keskinäisiä riippuvuuksia.

Korrelaatio on yksinkertainen tapa kuvata kahden muuttujan välistä riippuvuutta ja sitä tullaan käyttämään myös tässä tutkielmassa. Muuttujien välisen lineaarisen riippuvuuden voimakkuutta kuvataan korrelaatiokertoimen R ja selityskertoimen R^2 avulla. Korrelaatiokertoimen R arvo vaihtelee $[-1 - 1]$ välillä: sen ollessa -1 muuttujilla on täydellinen negatiivinen korrelaatio ja 1 , kun muuttujilla on täydellinen positiivinen korrelaatio. Korrelaation ollessa negatiivinen muuttujan Y arvo pienenee X :n arvojen kasvaessa ja toisin päin. Korrelaation ollessa positiivinen muutos tapahtuu samansuuntaisesti. Mitä suurempi korrelaatiokertoimen itseisarvo on, sitä tarkemmin muuttujien arvot voidaan laskea toistensa perusteella (Heino ym., 2012). Korrelaatiokertoimen ollessa 0 muuttujien välillä ei havaita lineaarista riippuvuutta.


Regressioanalyysin avulla puolestaan pyritään muodostamaan regressiomalli, jonka avulla voidaan selittää riippuvan muuttujan Y yhteys muihin muuttujiin X yhtälön (6.1) mukaisesti:

$$y = a + \sum bx \quad (6.1)$$

Yhtälössä a ja b ovat tuntemattomia vakioita, jotka pyritään arvioimaan (Heino ym., 2012). Hyvän regressiomallin tulee sisältää kaikki muuttujaan Y vaikuttavat riippumattomat muuttujat X , mutta käytännössä se on vaikeaa (Taanila, 2010).

6.2 Sosiaalinen vaikutus


Sääolojen lisäksi lämmöntarpeeseen vaikuttavat myös ns. sosiaaliset vaikutukset, jotka riippuvat kuluttajien käyttäytymisestä. Sosiaaliset vaikutukset muodostuvat niin lämpimän käyttöveden kulutuksen muutoksista kuin esimerkiksi asuntojen tai toimistotilojen lämmityksen tarpeen muutoksissa (Fang ja Lahdelma, 2016). Sosiaalisissa vaikutuksissa on selkeästi nähtävissä niin päivittäinen, viikoittainen kuin vuosittainen sykli. Päivittäisessä rytmissä huomataan ennen kaikkea ns. aamu- ja iltapiikit lämpimän veden tarpeen kasvun johdosta aamu- ja iltatunteina, jolloin valtaosa väestöstä on kotona (Kuva 6-1, vasen puoli).



Kuva 6-1. Keskimääräinen lämmöntuotantoteho ajanjaksolla 2015 – 2018 vuorokauden (vasen kuva) ja eri viikonpäivien aikana (oikea kuva). Vasemmassa kuvassa on selkeästi nähtävissä piikit lämmönkulutuksessa kello 7.00 ja 21.00 paikallista aikaa. Oikean kuvan keskiarvot on laskettu kolmella eri tapaa: niin, että arkipyhiä ei huomioida (sininen viiva), arkipyhät huomioidaan ikään kuin ne olisivat lauantaita (oranssi viiva) ja arkipyhät huomioidaan sunnuntaina (harmaa viiva).

Viikoittainen rytmi tarkoittaa, että lämmönkulutus on suurempaa arkipäivinä kuin viikonloppuisin. Toisaalta on huomattavissa myös eroja eri arkipäivien välillä (Kuva 6-1, oikea puoli). Kun lämmöntarpeen viikonpäiväkohtaiselle kulutukselle lasketaan keskiarvoja, arkipyhät aiheuttavat ongelmia, sillä niiden lämmönkulutus on huomattavasti vähäisempää kuin tavallisena arkipäivänä. Lämmönkulutuksen ”viikonpäivittäiset keskiarvot” on laskettu tässä kolmella eri tapaa: niin, että arkipyhät on huomioitu normaaleina arkipäivinä (Kuva 6-1, sininen viiva) tai joko huomioimalla arkipyhät lauantaksi (Kuva 6-1, oranssi viiva) tai sunnuntaiksi (Kuva 6-1, harmaa viiva). Vastaavat kuvat lämmöntuotantotehon vuorokautiselle ja viikonpäivien väliselle vaihtelulle huomioimalla joko pelkästään lämmityskausi (loka-maaliskuu), kevät- tai kesäkuukaudet löytyvät liitteestä 1 (Kuvat L1-1 – L1-3).

Vuosittaiseen lämmönkulutuksen sykliin vaikuttavat esimerkiksi lomakaudet, jolloin havaitaan normaalia vähäisempi lämmönkulutus. Tämä on havaittavissa erityisesti kesälomien aikaan heinä-elokuussa. Kesällä lämmöntarve on vähäistä myös lämpimän ulkolämpötilan vuoksi, mutta myös ilman lämpötilasta riippumattoman lämpimän veden kulutus on normaalia vähäisempää. Lämmönkulutuksen vuosittaiseen sykliin vaikuttavat voimakkaasti myös muutokset ulkolämpötilassa, mutta tämä ei sisälly sosiaalisiin vaikutuksiin (Kuva 6-2).



Kuva 6-2. Kaukolämmön tuotantotehon (MW) ja ilman lämpötilan (°C) kuukausikeskiarvot vuosina 2015 – 2018. Heinäkuun 2016 tuotantotehotiedot puuttuvat.

Kuvan 6-1 perusteella saadaan jonkinlainen käsitys tuotantotehon vuorokautisesta ja viikoittaisesta käyttäytymisestä, mutta sen perusteella ei kuitenkaan nähdä kuinka hyvin tuntikohtaiset arviot osuvat kohdalleen. Tämän vuoksi sosiaalisia vaikutuksia pyritään arvioimaan myös regressiomallin avulla, jossa tuntikohtaista lämmöntuotantomäärää arvioidaan vuorokausi- ja viikkorytmiin perustuvien ennusteiden avulla. Kun regressiomallin avulla pyritään arvioimaan koko vuoden lämmöntuotantotehoa, poikkeaa tuntikohtaisesti ennustettu tuotantoteho todellisesta jopa 66,3 %. Rajoittumalla pelkästään lämmityskauteen on tuntikohtainen virhe keskimäärin 21,2 %. Maalis-toukokuulle kohdistuva virhe on puolestaan huomattavasti suurempi: 40,8 %. Tarkimpaan tulokseen päästään rajoittumalla pelkästään kesäkuukausiin (kesä-elokuu), jolloin regressiomallin avulla laskettu tuntikohtainen tuotantoteho poikkeaa todellisesta tuotantotehosta keskimäärin 15,9 %. Regressiomallien tulokset on esitetty luvun lopussa taulukossa 6-1. Eri ajanjaksoista huolimatta regressiomallin avulla tarkin tulos saadaan, kun arkipyhiä ei huomioida ollenkaan (Kuva 6-1; Kuvat L1-1 – L1-3, oikea puoli, sininen viiva).


6.3 Sääparametrien vaikutus

Tässä osiossa tarkastellaan tuotantotehon ja sääparametrien välisiä korrelaatioita. Ensimmäisessä kappaleessa käsitellään koko vuoden tuloksia. Tämän jälkeen rajoitutaan loka-maaliskuun väliselle ajanjaksolle, jolloin lämmityksen tarve on kaikista suurin. Myöhemmin tarkastellaan vielä tuotantotehon ja sääparametrien välisiä yhteyksiä erikseen keväällä (”maalis-toukokuu”) ja kesällä (”kesä-elokuu”). Lämmönkulutusta pyritään ennustamaan edellisen kappaleen tavoin

lineaarisen regressiomallin avulla, jossa ulkolämpötilan lisäksi huomioidaan myös joko sosiaaliset vaikutukset, tuuli tai auringonsäteily.

6.3.1 Koko vuosi

Tarkastelemalla lämmöntuotantotehon ja lämpötilasta välistä yhteyttä vuosina 2015 – 2018 nähdään, että muuttujien välinen selityskerroin R^2 on 0,9119 ja korrelaatiokerroin $|R| = 0,9549$. Laskemalla kuvaajasta (6-3) saadun korrelaatioyhtälön perusteella lämmöntuotantoteho jokaiselle tunnille, poikkeaa pelkästään lämpötilaan perustuva tuntikohtainen tuotantoteho todellisesta tuotantotehosta keskimäärin 18,2 %.



Kuva 6-3. Kaukolämmön tuotantotehon (MW) ja ilman lämpötilan (°C) välinen lineaarinen riippuvuus vuosina 2015 – 2018.

Tuotantotehon ja lämpötilan välinen korrelaatio on todella vahva. Voidaan kuitenkin huomata, että muuttujien välinen riippuvuus on lineaarinen ainoastaan, kun lämpötilan on enintään n. 15 °C (Kuva 6-3). Kuten jo kappaleessa 2.4 todettiin, ulkoilman lämpötilan ollessa yli + 15 °C rakennuksia ei juurikaan tarvitse lämmittää ja kaukolämpöä kuluu lähinnä käyttöveden lämmittämiseen.


Muiden sääsuureiden ja tuotantotehon väliset korrelaatiot jäävät heikoiksi tai merkityksettömiksi (Liite 2: Kuva L2-1). Ainoat heikot korrelaatiot löytyvät lämmöntuotannon sekä globaalin säteilyn että suhteellisen kosteuden väliltä. Pilvisyyden, ilmanpaineen, sateen intensiteetin ja tuulen nopeuden väliset korrelaatiot tuotantotehon kanssa ovat merkityksettömiä.

Tuotantoteholle muodostettiin myös regressiomalli, jolla tuotantotehoa pyritään ennustamaan ulkolämpötilan ja sosiaalisten vaikutusten avulla tuntikohtaisesti. Malli perustuu jokaiseen

vuosien 2015 – 2018 tuntiin, joilta on saatavilla sekä tuotantotehomittaus että lämpötilahavainto. Regressiomallin avulla saatu tuotantoteho poikkeaa todellisesta tehosta keskimäärin 17,3 %. Erityisesti ulkolämpötilan ollessa korkea, malli epäonnistuu täysin tuotannon arvioinnissa. Suurin yksittäiselle tunnille kohdistuvan virheen suuruus on jopa 220 %: tosin kyseisen tunnin lämpötila on 30,8 °C. Kaikkien niiden tuntien, joille arvioidun tuotantotehon suuruus poikkeaa todellisesta yli 100 %, keskilämpötila on 24,2 °C. Tuulen nopeuden, ilman kosteuden ja auringonsäteilyn huomioiminen regressiomallissa laskee hieman tuntikohtaista keskivirhettä, mutta samalla suurimmat yksittäisille tunneille kohdistuvat ennustevirheet kasvavat. Huomioimalla joko tuulen nopeuden tai auringonsäteilyn vaikutus ulkolämpötilan kanssa ilman sosiaalisia vaikutuksia, poikkeaa ennustettu lämmöntuotantoteho todellisesta n. 17,5 %.

6.3.2 Lämmityskausi

Tässä kappaleessa rajoitutaan sääsuureiden ja tuotantotehon välisiin yhteyksiin ”lämmityskauden aikana”, joka on tässä rajoitettu loka-maaliskuun välille. Kuten jo huomattiin, tuotantotehon ja lämpötilan välinen yhteys on lineaarinen ainoastaan lämpötilan ollessa alle + 15 °C. Tätä korkeammilla ulkoilman lämpötiloilla lämpötilan ja tuotantotehon välinen yhteys on huomattavasti heikompi.




Kuva 6-4. Kaukolämmön tuotantotehon (MW) ja ilman lämpötilan (°C) välinen lineaarinen riippuvuus loka-maaliskuussa vuosina 2015 – 2018.

Lämmityskaudelle rajoituttaessa tuotantotehon ja lämpötilan välillä on vahva selityskertoimen $R^2 = 0,9046$ ja korrelaatiokerroin $|R| = 0,9511$ (Kuva 6-4). Ulkolämpötilan ja tuotantotehon välinen korrelaatio on hieman heikompi, kun rajoitutaan loka-maaliskuun väliselle ajanjaksolle eikä

tarkastella kokonaisia vuosia. Kuitenkin arvioimalla tarvittavan tuotantotehon suuruutta tuntikohtaisesti kuvaajasta (6-4) saatavan korrelaatioyhtälön perusteella, eroaa arvioitu tuotantotehon määrä todellisesta keskimäärin enää 6,7 %. Lämpötilaa lukuun ottamatta muiden sääsuureiden ja tuotantotehon väliset selityskertoimet R^2 ovat niin matalat, että niiden välistä yhteyttä voidaan pitää merkityksettömänä (Liite 2, Kuva L2-2).

Lämmityskaudelle on myös mielenkiintoista nähdä, korreloiko ”tuntuu kuin” -lämpötila tuotantotehon kanssa, sillä siinä huomioidaan myös ilman kosteuden ja tuulen viilentävät vaikutukset. Voidaan kuitenkin havaita, että tuntuu kuin -lämpötilan ja tuotantotehon välinen korrelaatio on alhaisempi kuin normaalin lämpötilan kanssa (Kuva 6-5).



Kuva 6-5. Kaukolämmön tuotantotehon (MW) ja ”tuntuu kuin” -lämpötilan (°C) välinen lineaarinen riippuvuus loka-maaliskuussa vuosina 2015 – 2018. ”Tuntuu kuin” -lämpötila on esitelty luvussa 3.


Lämmityskauden tuotantoteholle muodostettiin myös regressiomalli, jossa huomioitiin lämpötilan lisäksi sosiaaliset vaikutukset. Mallin ennustetarkkuus parani todella paljon sen rajoittuessa pelkästään loka-maaliskuun väliseen ajankohtaan: tuntikohtaisesti arvioitu tuotantoteho poikkeaa todellisesta nyt vain 6,0 %. Tulos on siis hieman parempi, kun lämpötilan lisäksi myös sosiaaliset vaikutukset huomioitiin regressiomallissa. Muiden sääparametrien, kuten tuulen nopeuden, ilman kosteuden tai säteilyn vaikutusten lisääminen malliin pienensi keskimääräistä tuntikohtaista ennustusvirhettä, mutta tässäkin tapauksessa kasvatti suurimpia yksittäisiin tunteihin kohdistuvia virheitä.

Tuotantotehon arviointi on vaikeaa tilanteissa, joissa lämpötila muuttuu nopeasti (Liite 3: Kuva L3-1 – Kuva L3-3). Esimerkiksi lämpötilan laskiessa malli olettaa lämmöntarpeen kasvavan nopeammin kuin miten se todellisuudessa kasvaa. Vastaava ilmiö havaitaan lämpötilan

kasvaessa, sillä mallin ennustama lämmöntarve laskee todellista nopeammin. Tästä esimerkkinä joulukuun 2015 loppu ja tammikuun 2016 alku, jolloin Suomessa oli todella kylmä (Liite 3: Kuva L3-1). Lämpötilan laskiessa joulukuun lopulla malli arvioi lämmön tarpeen kasvavan aluksi todellista tarvetta suuremmaksi. Kylmän jakson loppupuolella malli sen sijaan onnistui ennustuksessa jo paremmin. Mallista siis puuttuu ikään kuin viive, joka huomioisi edellisten tuntien ja/tai päivien lämpötilan vaikutuksen. Talven 2016 – 2017 aikana regressiomalli pystyi ennustamaan melko hyvin lämmön tarpeen lukuun ottamatta lokakuuta 2016, jolloin malli selvästi aliarvioi lämmöntarvetta (Liite 3: Kuva L3-2). Myös talven 2017 – 2018 aikana regressiomallin ennustama lämmöntarve osui melko hyvin kohdilleen vuoden vaihdetta lukuun ottamatta (Liite 3: Kuva L3-3): Äkillinen lämmöntarpeen romahdus lämpötilan pysyessä melko tasaisena vaikuttaa siltä, että lämmöntuotantodataan on jäänyt mittausvirhe.

6.3.3 Kevät ja kesä

Tässä osiossa tutkitaan lämmönkulutuksen ja sääparametrien välistä yhteyttä kuukausina, jolloin lämmitystarve on vähäisempää. Osiossa käsitellään erikseen maalis-toukokuuta ja kesä-elokuuta, jotta kylmät kevätlämpötilat eivät vaikuttaisi kesän tuloksiin ja toisin päin. Lisäksi on mielenkiintoista nähdä, onko auringon säteilyn vaikutus lämmöntarpeeseen keväällä suurempi kuin tavallisesti.




Kuva 6-6. Kaukolämmön tuotantotehon (MW) ja ilman lämpötilan (°C) välinen lineaarinen riippuvuus maalis-toukokuussa vuosina 2015 – 2018.

Maalis-toukokuun välisellä ajanjaksolla tuotantotehon ja lämpötilan välinen korrelaatio on vahva: selityskerroin $R^2 = 0,8847$ ja korrelaatiokerroin $|R| = 0,9406$ (Kuva 6-6). Kuitenkin

arvioimalla lämmöntuotantotehoa kuvaajan (6-6) korrelaatioyhtälön perusteella, on tuntikohtaisen keskivirheeseen suuruus 13,0 %. Maalis-toukokuussa lämpötilassa havaittavat tuntikohtaiset vaihtelut ovat hyvin voimakkaita: kylmin lämpötilamittaus on -23,1 °C ja korkein 28,6 °C. Maalis-toukokuussa lämmöntuotantotehon havaitaan korreloivan heikosti ilman kosteuden ($R^2 = 0,2026$, $|R| = 0,4501$) ja globaalin säteilyn ($R^2 = 0,1969$, $|R| = 0,4437$) kanssa. Muiden tutkittujen sääsuureiden ja tuotantotehon väliset korrelaatiot ovat merkityksettömiä (Liite 2: Kuva L2-3).

Kesä-elokuussa tuotantotehon lämpötilariippuvuus on selkeästi aikaisempia esimerkkejä heikompi: $R^2 = 0,5108$ eli $|R| = 0,7147$ (kuva 6-7). Kuvaajan 6-7 korrelaatioyhtälön perusteella ennustettu lämmöntuotanto vastaa kuitenkin todellisen tuotannon suuruutta paremmin kuin rajoittumalla maalis-toukokuun väliselle ajanjaksolle. Tuntikohtaisen keskivirheen suuruus on nyt 11,6 %. Lämpötilan lisäksi muiden sääsuureiden ei havaita korreloivan lämmöntuotantotehon kanssa kesä-elokuussa (Liite 2: Kuva L2-4).



Kuva 6-7. Kaukolämmön tuotantotehon (MW) ja ilman lämpötilan (°C) välinen lineaarinen riippuvuus kesä-elokuussa vuosina 2015 – 2018.

Kevätkuukausille muodostetun regressiomallin ennustama tuotantoteho poikkeaa todellisesta tehosta keskimäärin 12,2 % mallin huomioidessa sosiaaliset vaikutukset ja ilman lämpötilan. Muiden sääsuureiden lisääminen regressiomalliin ei paranna tuloksia merkittävästi. Esimerkiksi säteilyn huomioiminen mallissa ilman lämpötilan ja sosiaalisten vaikutusten lisäksi aiheuttaa ennustetun ja todellisen tuotantotehon välille vieläkin 12,0 % keskivirheen. Vaikka tuntikohtainen keskivirhe laskeekin hieman, kasvavat suurimmat tuntiarvojen virheet. Kesäkuukausille saadut tulokset ovat suuruusluokaltaan samanlaisia: todellisen ja ennustetun

lämmöntuotannon välinen tuntikohtainen keskivirhe on 11,4 % regressiomallin huomioidessa sosiaalisen vaikutuksen ja ilman lämpötilan.

Tässä kappaleessa saadut regressiomallien tulokset on esitetty lyhyesti taulukossa 6-1. Kuten huomataan, tarkimpaan tulokseen päästään yleensä, kun regressiomallissa huomioidaan sekä sosiaaliset vaikutukset että ulkoilman lämpötila. Säteilyn ja/tai tuulen nopeuden huomioiminen näiden lisäksi pienentää keskimääräistä virhettä n. 0,2 %, mutta kasvattaa suurimpia yksittäisiä tuntikohtaisia virheitä jopa yli 20 %.

Taulukko 6-1. Regressiomallien avulla arvioitujen tuntikohtaisten lämmöntuotantotehojen keskimääräinen prosentuaalinen ero todellisesta lämmöntuotantotehosta.

Ajanjakso	Sosiaaliset vaikutukset	Lämpötila	Sosiaaliset vaikutukset ja lämpötila	Lämpötila ja säteily	Lämpötila ja tuulen nopeus
Koko vuosi, 2015 – 2018	66,3 %	18,2 %	17,3 %	17,5 %	17,5 %
Loka-maaliskuu	21,2 %	6,7 %	6,0 %	6,6 %	6,6 %
Maalis-toukokuu	40,8 %	13,0 %	12,2 %	12,8 %	12,6 %
Kesä-elokuu	15,9 %	11,6 %	11,4 %	11,3 %	11,3 %

7. Johtopäätelmät

Kaukolämmön tarpeen havaittiin korreloivan hyvin niin ulkolämpötilan kuin sosiaalisten vaikutusten kanssa. Sen sijaan muiden sääsuureiden ja kaukolämmöntarpeen välillä ei huomattu lähes minkäänlaista korrelaatiota. Ainoastaan ilman kosteuden ja auringonsäteilyn havaittiin korreloivan heikosti tuotantotehon kanssa. Näistä molempien korrelaatiokerroin tuotantotehon kanssa kasvoi hieman, kun rajoituttiin pelkästään maaliskuuun väliselle ajanjaksolle, mutta loka-maaliskuussa ja kesä-elokuussa niidenkin välinen korrelaatio oli merkityksetöntä.

Näin ollen ulkolämpötilaa lukuun ottamatta muiden sääparametrien käyttö kaukolämmön tarpeen optimoinnissa on merkityksetöntä. Sen sijaan ulkolämpötilan ja kaukolämmön tarpeen välinen korrelaatio on todella hyvä: vuosien 2015 – 2018 kaukolämmön tuotantoteho- ja lämpötilamittausten välinen korrelaatiokerroin oli jopa 0,9546. Korrelaatiokerroin oli lähes yhtä hyvä, kun rajoituttiin loka-maaliskuun väliselle ajanjaksolle. Taulukon 6-1 perusteella ulkolämpötila on tärkein kaukolämmöntarpeeseen vaikuttava yksittäinen tekijä. Sosiaalisten vaikutusten huomioinen optimoinnissa ja mahdollisissa kaukolämpöennusteissa on kuitenkin tärkeää ympäri vuoden. Vaikka sosiaalisten vaikutusten huomioiminen kaukolämmön optimoinnissa ilman ulkolämpötilaa aiheuttaakin suuria tuntikohtaisia virheitä, parani mallin ennustetarkkuus kaikkina ajanjaksoina, kun myös sosiaaliset vaikutukset huomioitiin regressiomallissa ulkolämpötilan lisäksi (Taulukko 6-1).

Loka-maaliskuulle muodostettu lineaarinen regressiomalli onnistui melko hyvin tuotantotehon arvioinnissa. Regressiomallissa tuotantotehoa arvioitiin sosiaalisten vaikutusten ja ulkolämpötilan avulla. Mallin perusteella arvioitu tuntikohtainen lämmöntuotantoteho poikkesi todellisesta tehosta keskimäärin n. 6 %. Suurimmat mallissa havaittavista virheistä johtuivat joko mittausvirheistä tai mallin arvioidessa lämmöntuotantotehon muuttuvan liian nopeasti tilanteissa, joissa ilman lämpötila muuttui nopeasti. Mallin tuloksien tarkentamiseksi siihen tulisikin lisätä hitausominaisuus tai ns. ”viive”, joka säätelisi kaukolämmön tarvetta tilanteissa, joissa ulkolämpötila muuttuu nopeasti.

Lämpötilaennusteita lukuun ottamatta sääennusteiden ja säähavaintojen pohjalta ei pystytä tarkentamaan kaukolämmöntarpeenennusteita, ainakaan pelkästään lineaarista regressioanalyysiä käyttämällä. Sen sijaan koneoppimista hyväksi käyttäen säähavaintojen avulla on saatu todella

hyviä tuloksia (Pöyry Finland 2019). Virheitä kaukolämmöntarpeen optimoinnissa aiheutuu luonnollisesta myös lämpötilaennusteiden virheistä.

Kiitokset

Haluan kiittää ohjaajiani Jouni Räisästä ja Heikki Järvistä monipuolisista neuvoista ja hyvistä kommentteista tämän Pro gradu -tutkielman kirjoituksen aikana ja myös työn arvioinnista. Lisäksi haluan kiittää Pöyry Finland Oy:tä ja erityisesti esimiestäni Jouni Laukkasta tämän tutkielman mahdollistamisesta ja hyvistä neuvoista kaukolämpöosuuteen liittyen.

LÄHDELUETTELO

- Alatalo, M. (2009). Havaintojärjestelmäkokeet numeerisessa sään ennustamisessa. Helsingin yliopisto.
- Avoindata.fi. (2019). Sääennustusdata HARMONIE-AROME. [Verkkojulkaisu] [Viitattu 14.4.2019] Saatavilla: https://www.avoindata.fi/data/en_GB/dataset/saaennustedata-harmonie-arome
- Bouttier, F. & P. Courtier. (1999) Data assimilation concepts and methods. Meteorological Training Course Lecture Series. ECMWF, 2002.
- Cai, Q., W. Wang & S. Wang. (2015). Multiple regression model based on weather factors for predicting the heat load of a district heating system in Dalian, China – A case study
- ECMWF A. Data assimilation. [Verkkojulkaisu] [Viitattu 28.1.2019] Saatavilla: <https://www.ecmwf.int/en/research/data-assimilation>
- ECMWF B. Documentation and support. [Verkkojulkaisu] [Viitattu 30.1.2019] Saatavilla: <https://www.ecmwf.int/en/forecasts/documentation-and-support>
- ECMWF C. Fact sheet: Ensemble weather forecasting. [Verkkojulkaisu] [Viitattu 29.1.2019] Saatavilla: <https://www.ecmwf.int/en/about/media-centre/fact-sheet-ensemble-weather-forecasting>
- ECMWF D. Medium-range forecast. [Verkkojulkaisu] [Viitattu 29.1.2019] Saatavilla: <https://www.ecmwf.int/en/forecasts/documentation-and-support/medium-range-forecasts>
- ECMWF. (2017). How to pin down uncertainty in weather forecasting. [Verkkojulkaisu] [Viitattu 29.1.2019] Saatavilla: <https://www.ecmwf.int/en/about/media-centre/news/2017/how-pin-down-uncertainty-weather-forecasting>
- ECMWF. (2019). Improving ocean observations for better weather forecasts. [Verkkojulkaisu] [Viitattu 18.4.2019] Saatavilla: <https://www.ecmwf.int/en/about/media-centre/focus/improving-ocean-observations-better-weather-forecasts>
- Eduskunta. (2018). Hallituksen esitys HE 200/2018 vp. [Verkkojulkaisu] [Viitattu 17.4.2019] Saatavilla: https://www.eduskunta.fi/FI/vaski/HallituksenEsitys/Sivut/HE_200+2018.aspx
- Energiateollisuus. (2006). Kaukolämmön käsikirja. Energiateollisuus ry. 566 s. ISBN 952-5615-08-1

Energiatoteellisuus. (2017). Energiavuosi 2016 – Kaukolämpö. [Verkojulkaisu] [Viitattu 8.1.2019]

Saatavilla: https://energia.fi/ajankohtaista_ja_materiaalipankki/materiaalipankki/kaukolamppo_2016_graafina.html#material-view

Eresmaa, R. Data-assimilaation menetelmät. Ilmatieteen laitos. Saatavilla: <http://hirlam.fmi.fi/hydmet/eresmaa.pdf>

Fang, T. & R. Lahdelma. (2016). Evaluation of a multiple linear regression model and SARIMA model in forecasting heat demand for district heating system. Applied Energy 179 (2016) 544–552

FAO. Chapter 3 – Meteorological data. [Verkojulkaisu] [Viitattu 5.2.2019] Saatavilla: <http://www.fao.org/docrep/X0490E/x0490e07.htm>

Fingrid. Säätosähkö- ja säätökapasiteettimarkkinat. [Verkojulkaisu] [Viitattu 15.1.2019] Saatavilla: <https://www.fingrid.fi/sahkomarkkinat/reservit-ja-saatosahko/saatosahko--ja-saatokapasiteettimarkkinat/#saatosahkon-hinnoittelu>

Hashemi, K. (2009). Station Distribution. [Verkojulkaisu] [Viitattu 28.1.2019] Saatavilla: <http://homeclimateanalysis.blogspot.com/2009/12/station-distribution.html>

Heino, R., K. Ruosteenoja & J. Räisänen. (2012). Havaintojen tilastollinen käsittely. Helsingin yliopisto

HIRLAM. (2016). Welcome to HIRLAM! [Verkojulkaisu] [Viitattu 28.1.2019] Saatavilla: <http://hirlam.org/index.php/hirlam-programme-53>

Holopainen, E., C. Fortelius, K. Ruosteenoja & J. Räisänen. (2008) Ilmakehän yleinen kiertoliike 1. Helsingin yliopisto.

Ilmatieteen laitos A. Havaintojen lataus. [Verkojulkaisu] [Viitattu 15.1.2019] Saatavilla: <https://ilmatieteenlaitos.fi/havaintojen-lataus#!/>

Ilmatieteen laitos B. Lämpötila ja kosteus. [Verkojulkaisu] [Viitattu 17.4.2019] Saatavilla: <https://ilmatieteenlaitos.fi/lampotila-ja-kosteus>

Ilmatieteen laitos C. Pilvet säätelevät lämpötilan vuorokausivaihtelua eri vuoden aikoina. [Verkojulkaisu] [Viitattu 14.1.2019] Saatavilla: <https://ilmatieteenlaitos.fi/pilvisyyden-merkitys-lampotilaan>

Ilmatieteen laitos D. Sääennustedata. [Verkojulkaisu] [Viitattu 22.4.2019] Saatavilla: <https://ilmatieteenlaitos.fi/avoin-data-saaennustedata-hirlam>

Ilmatieteen laitos. (2012a) Juttusarja: Sääennusteiden teossa säätyyppi ja vuodenaika vaikuttavat – KESÄ. [Verkkojulkaisu] [Viitattu 28.1.2019] Saatavilla: <https://ilmatieteenlaitos.fi/ajankohtaista/519945>

Ilmatieteen laitos. (2012b) Juttusarja: Sääennusteiden teossa säätyyppi ja vuodenaika vaikuttavat – TALVI. [Verkkojulkaisu] [Viitattu 28.1.2019] Saatavilla: <https://ilmatieteenlaitos.fi/ajankohtaista/464015>

Ilmatieteen laitos. (2015a) Havainnoista kaikki alkaa. [Verkkojulkaisu] [Viitattu 28.1.2019] Saatavilla: <https://ilmatieteenlaitos.fi/havainnoista-kaikki-alkaa>

Ilmatieteen laitos. (2015b). Laskentajärjestelmä. [Verkkojulkaisu] [Viitattu 28.1.2019] Saatavilla: <https://ilmatieteenlaitos.fi/laskentajarjestelma>

Ilmatieteen laitos.(2015c). Mallityyppi riippuu käyttötarkoituksesta. [Verkkojulkaisu] [Viitattu 28.1.2019] Saatavilla: <https://ilmatieteenlaitos.fi/mallityyppi-riippuu-kayttotarkoituksesta>

Ilmatieteen laitos. (2018a). Kuinka pitkälle säätä voi ennustaa. [Verkkojulkaisu] [Viitattu 28.1.2019] Saatavilla: <https://ilmatieteenlaitos.fi/kuinka-pitkalle-saata-voi-ennustaa>

Ilmatieteen laitos. (2018b). Sääennusteet ovat parantuneet viime vuosina. [Verkkojulkaisu] [Viitattu 17.4.2019] Saatavilla: <https://ilmatieteenlaitos.fi/saaennusteet-parantuvat>

Järvinen, H. (2015). Numeerinen meteorologia 1. Helsingin yliopisto.

Kontu, K., S. Rinne, V. Olkkonen, R. Lahdelmaa & P. Salminen. (2015). Multicriteria evaluation of heating choices for a new sustainable residential area. *Energy and Buildings*. Volume 93, 15 April 2015, Pages 169-179

Kostelich, E. J., Y. Kuang, J. M. McDaniel, N. Z. Moore, N. L. Martirosyan & M. C. Preul. (2011). Accurate state estimation from uncertain data and models: an application of data assimilation to mathematical models of human brain tumors. *Biology direct* 2011, 6:64.

Kwak, Y., D. Seo, C. Jang & J. Huh. (2012). Feasibility study on a novel methodology for short-term real-time energy demand prediction using weather forecasting data. *Energy and Buildings* 57 (2013) 250–260

Laaksonen, L. (2018). Kaukolämmön menoveden lämpötilan taloudellinen optimointi. Lappeenrannan teknillinen yliopisto.

Motiva. (2017). Mitä ovat lämmitystarveluvut? [Verkkojulkaisu] [Viitattu 7.1.2019] Saatavilla:
https://www.motiva.fi/julkinen_sektori/kiinteiston_energian kaytto/kulutuksen_normitus/mita_ovat_lammitystarveluvut

Nord Pool. [Verkkojulkaisu] [Viitattu 14.1.2019] Saatavilla:
<https://www.nordpoolgroup.com/>

Nousiainen, T. & A-M. Sundström.(2014). Tutka- ja kaukokartoitusmeteorologian luentomuistiinpanot. Helsingin yliopisto.

Ollikka, K., (2017). Miten sähkömarkkinat toimivat? Smart Energy Transition [Verkkojulkaisu] [Viitattu 14.1.2019] Saatavilla: <http://smartenergytransition.fi/fi/miten-sahkomarkkinat-toimivat/>

Pori Energia. Yhteistuotanto. [Verkkojulkaisu] [Viitattu 25.3.2019] Saatavilla:
<https://www.porienergia.fi/Tietoa/Ymparisto/Yhteistuotanto/#.XJiTuvkzZaQ>

Puhakka, T. (1996) Dynamiikka I. Helsingin yliopisto.

Pöyry Finland Oy. (2019). Tuntimittausdata kaukolämpöyhtiöiltä.

Randall, J. O. (1995). The Basis of Wind Chill. Arctic Institute of North America. Vol. 48, No. 4 (Dec., 1995), pp. 372-382

Rinne, J. & S. Haapalanala. (2009). Meteorologinen mittalaitetekniikka.

Ruosteenoja, K. (1996). Meteorologian perusteet. Helsingin yliopisto.

Räisänen, J. (2010). Fysikaalinen klimatologia. Helsingin yliopisto.

Safa, M., J. Allen & M. Safa. (2014) Predicting Energy Usage Using Historical Data and Linear Models. The 31st International Symposium on Automation and Robotics in Construction and Mining.

Siiskonen, V.(2015). Parviennusteen satunnaishäiriö- ja jalostushäiriömenetelmä Lorenz-96-mallissa. Helsingin yliopisto.

Taanila, A. (2010). Lineaariset regressiomallit. [Verkkojulkaisu] [Viitattu 7.1.2019] Saatavilla: <http://myy.haaga-helia.fi/~taaak/m/regressio.pdf>

Talouselämä. (2019). Suomeen viritetään valtavaa lämmityskeikausta – lämpöpumpuilla keskeinen rooli, tähtäimessä kuusinkertaistaminen. [Verkkojulkaisu] [Viitattu 14.1.2019] Saatavilla:
<https://www.talouselama.fi/uutiset/te/acf05df8-1920-3206-b466-a30cd1448735>

Tilastokeskus. (2017). Energian kokonaiskulutus nousi 2 prosentti vuonna 2016. [Verkkojulkaisu] [Viitattu 14.1.2019] Saatavilla: http://tilastokeskus.fi/til/ehk/2016/04/ehk_2016_04_2017-03-23_tie_001_fi.html

Tuuliatlas A. Mitä tuuli on? [Verkkojulkaisu] [Viitattu 5.2.2019] Saatavilla: http://www.tuuliatlas.fi/tuulisuus/tuulisuus_2.html

Tuuliatlas B. Mikä on mesoskaala? [Verkkojulkaisu] [Viitattu 18.4.2019] Saatavilla: http://www.tuuliatlas.fi/mallinnus/mallinnus_8.html

Vallinheimo, E (2016). Säämalli – nykypäivän ennustetehdas. Atmoslehti. [Verkkojulkaisu] [Viitattu 29.1.2019] Saatavilla: <https://atmoslehti.fi/teema/saamalli-nykypaivan-ennustetehdas-2/Fatmos>

Vas3k (2018). How Machines Predict The Weather For US. [Verkkojulkaisu] [Viitattu 10.4.2019] Saatavilla: https://vas3k.com/blog/how_to_weather/


Werner, S. (1984) The heat load in district heating systems.

Wind Energy The Facts. Power Markets. [Verkkojulkaisu] [Viitattu 14.1.2019] Saatavilla: <https://www.wind-energy-the-facts.org/power-markets-7.html>

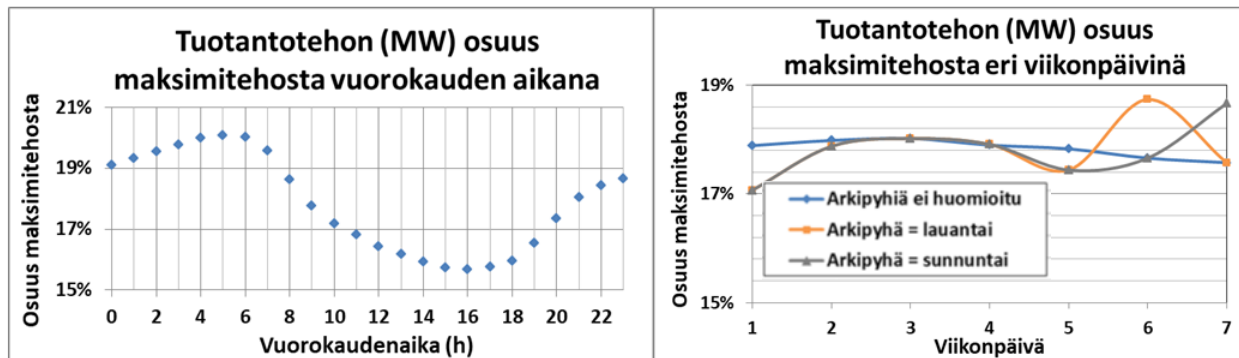
Wojdyga, K. (2008) An influence of weather conditions on heat demand in district heating systems. Energy and Buildings 40 (2008) 2009–2014

World Meteorological Organization. Global Observing System. [Verkkojulkaisu] [Viitattu 28.1.2019] Saatavilla: <https://public.wmo.int/en/programmes/global-observing-system>


Liite 1: Sosiaaliset vaikutukset



Kuva LI-1. Keskimääräinen lämmöntuotantoteho vuorokauden (vasen kuva) ja eri viikonpäivien aikana (oikea kuva) loka-maaliskuussa ajanjaksolla 2015 – 2018. Vasemmassa kuvassa on selkeästi nähtävissä piikit lämmönkulutuksessa kello 8.00 ja 20.00 paikallista aikaa. Oikeassa kuvassa keskiarvot on laskettu kolmella eri tapaa: niin, että arkkipyhä ei huomioida (sininen viiva), arkkipyhät huomioidaan ikään kuin ne olisivat lauantaita (oranssi viiva) ja arkkipyhät huomioidaan sunnuntaina (harmaa viiva).



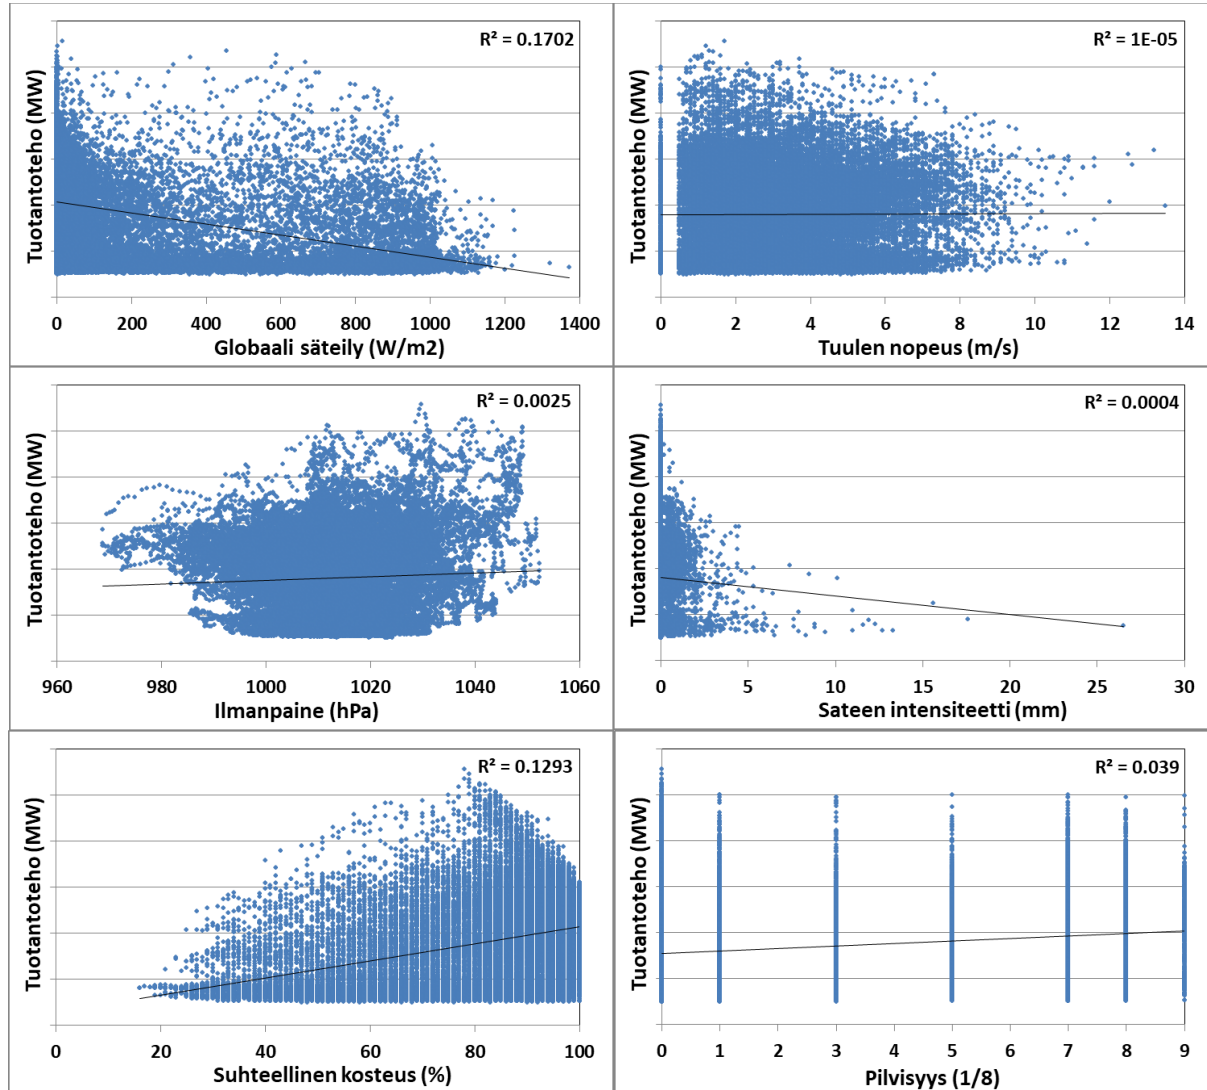
Kuva LI-2. Keskimääräinen lämmöntuotantoteho vuorokauden (vasen kuva) ja eri viikonpäivien aikana (oikea kuva) maaliskuu-toukokuussa ajanjaksolla 2015 – 2018. Vasemmassa kuvassa on nähtävissä piikki lämmönkulutuksessa kello 4–6 ja toinen, ei niin selkeä piikki kello 22–23 paikallista aikaa. Oikeassa kuvassa keskiarvot on laskettu kolmella eri tapaa: niin, että arkkipyhä ei huomioida (sininen viiva), arkkipyhät huomioidaan ikään kuin ne olisivat lauantaita (oranssi viiva) ja arkkipyhät huomioidaan sunnuntaina (harmaa viiva).



Kuva LI-3. Keskimääräinen lämmöntuotantoteho vuorokauden (vasen kuva) ja eri viikonpäivien aikana (oikea kuva) kesä-elokuussa ajanjaksolla 2015 – 2018. Vasemmassa kuvassa on nähtävissä piikki lämmönkulutuksessa kello 4 ja toinen, ei niin selkeä piikki kello 23 paikallista aikaa. Oikeassa kuvassa keskiarvot on laskettu kolmella eri tapaa: niin, että arkipyhiä ei huomioida (sininen viiva), arkipyhät huomioidaan ikään kuin ne olisivat lauantaita (oranssi viiva) ja arkipyhät huomioidaan sunnuntaina (harmaa viiva).

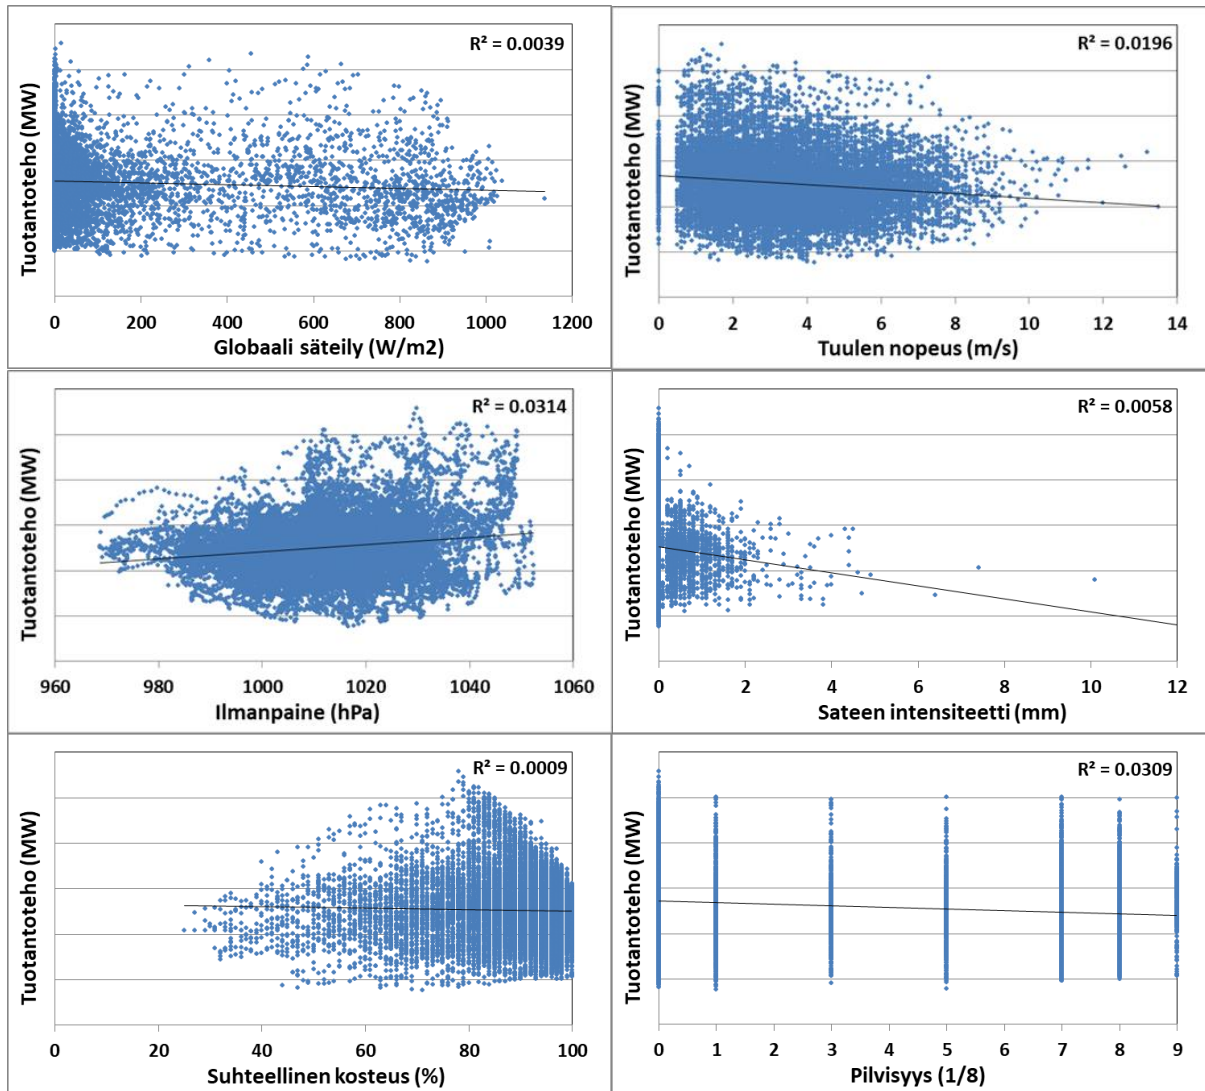
Liite 2: Sääparametrien vaikutus

Koko vuosi



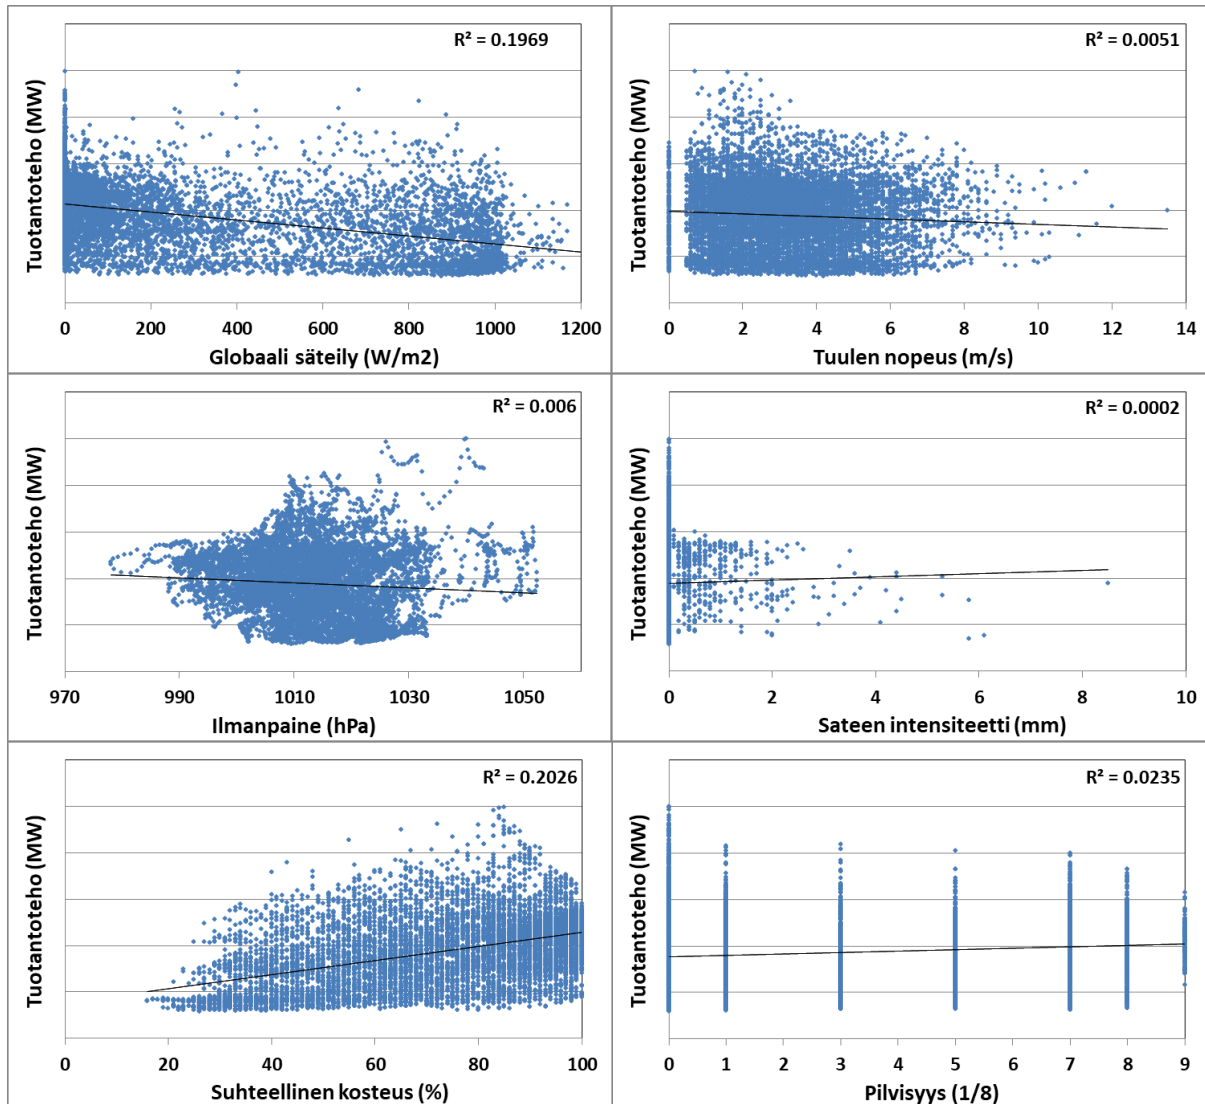
Kuva L2-1. Kaukolämmön tuotantotehon ja eri sääsuureiden väliset korrelaatiot ja selityskertoimet R^2 vuosina 2015 – 2018. Muuttujien välinen yhteys on heikko, kun $0,3 < |R| < 0,7$ eli $0,09 < R^2 < 0,49$. Ainoastaan suhteellisen kosteuden ja globaalin säteilyn välinen yhteys tuotantotehon kanssa on heikko; ilmanpaine, tuulen nopeus, sateen intensiteetti ja pilvisuus eivät korrelaatiokertoimen perusteella vaikuta yksinään tuotantotehoon.

Lämmityskausi, loka-maaliskuu



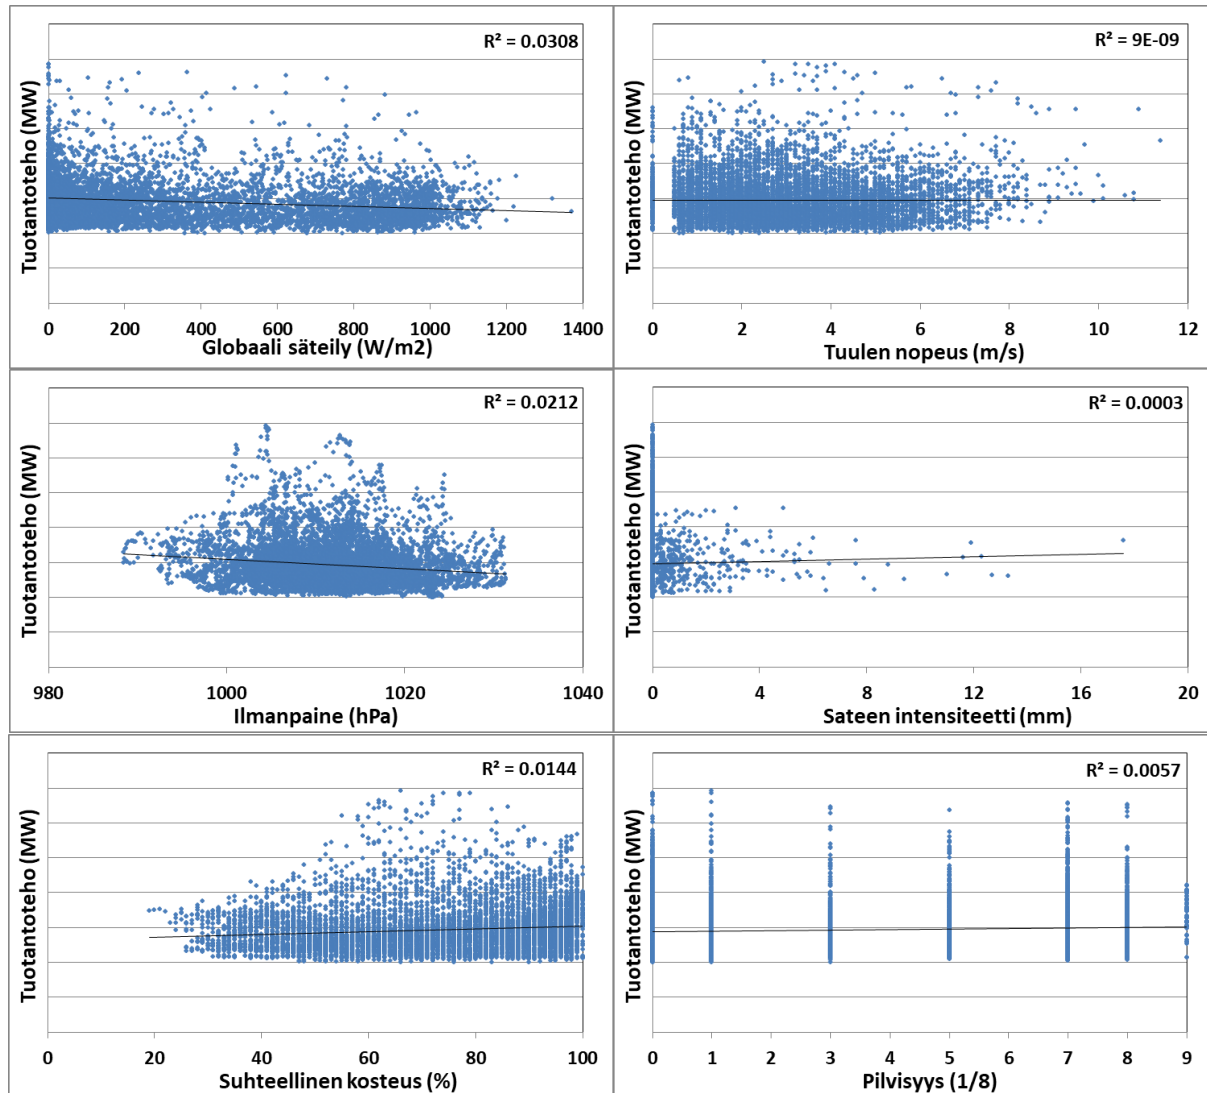
Kuva L2-2. Kaukolämmön tuotantotehon ja eri sääsuureiden väliset korrelaatiot ja selityskertoimet R^2 vuosina 2015 – 2018 loka-maaliskuussa. Muuttujien välinen yhteys on heikko, kun $0,3 < |R| < 0,7$ eli $0,09 < R^2 < 0,49$. Yhdenkään yllämainituista sääsuureista ei havaita korreloivan tuotantotehon kanssa

Maalis-toukokuu




Kuva L2-3. Kaukolämmön tuotantotehon ja eri sääsuureiden väliset korrelaatiot ja selityskertoimet R^2 vuosina 2015 – 2018 maalis-toukokuussa. Muuttujien välinen yhteys on heikko, kun $0,3 < |R| < 0,7$ eli $0,09 < R^2 < 0,49$. Ainoastaan suhteellisen kosteuden ja globaalin säteilyn välinen yhteys tuotantotehon kanssa on heikko; ilmanpaine, tuulen nopeus, sateen intensiteetti ja pilvisyys eivät korrelaatiokertoimen perusteella vaikuta yksinään tuotantotehoon.

Kesä-elokuu




Kuva L2-4. Kaukolämmön tuotantotehon ja eri sääsuureiden väliset korrelaatiot ja selityskertoimet R^2 vuosina 2015 – 2018 loka-maaliskuussa. Muuttujien välinen yhteys on heikko, kun $0,3 < |R| < 0,7$ eli $0,09 < R^2 < 0,49$. Yhdenkään yllämainituista sääsuureista ei havaita korreloivan tuotantotehon kanssa.


Liite 3: Regressiomallin tulokset



Kuva L3-1. Lämpötila (°C), tuotantoteho (MW), regressiomallilla ennustettu tuotantoteho ja absoluuttinen virhe (%) todellisesta tuotantotehosta loka-maaliskuu 2015–2016.



Kuva L3-2. Lämpötila (°C), tuotantoteho (MW), regressiomallilla ennustettu tuotantoteho ja absoluuttinen virhe (%) todellisesta tuotantotehosta loka-maaliskuu 2016–2017.



Kuva L3-3. Lämpötila (°C), tuotantoteho (MW), regressiomallilla ennustettu tuotantoteho ja absoluuttinen virhe (%) todellisesta tuotantotehosta loka-maaliskuussa 2017–2018.